

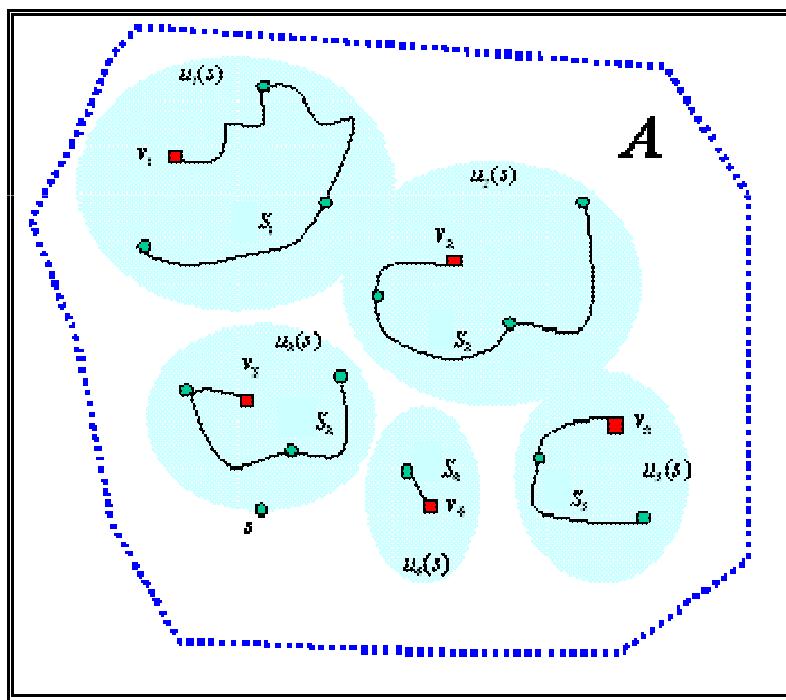
# **Estrategias en Tiempo Real para optimizar Operaciones de Transporte Público y Despacho de Vehículos: un enfoque de Control Predictivo**

**\*C.E. Cortés, D. Sáez**

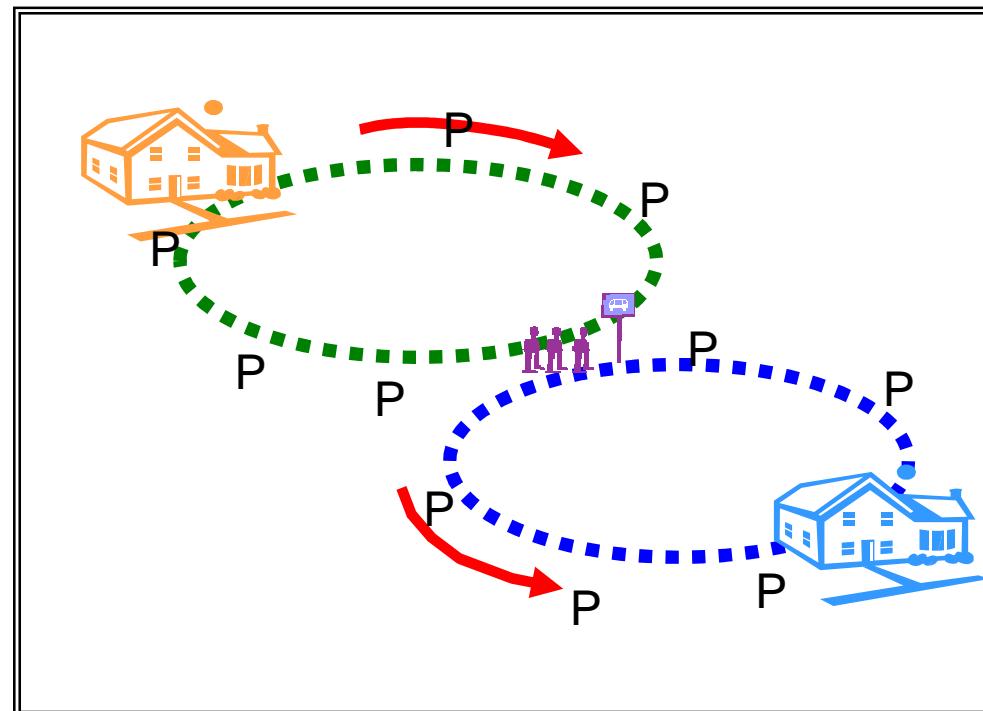
**Departamentos de Ingeniería Eléctrica  
e \*Ingeniería Civil  
Universidad de Chile**

# MOTIVACIÓN

- Optimización y modelación de sistemas públicos de transporte con demanda dinámica.



Dial-a-ride



Public transport

# Motivación

- Demanda dinámica: se genera en **tiempo real**
- Optimización de recursos (pasajeros y operador) considerando información histórica de demanda y velocidad (modelo predictivo) o bien información online
- Enfoque de Control Predictivo Adaptivo Híbrido para modelar sistemas: modelo en tiempo discreto
- Paso variable ( $k$ ) y depende del tiempo entre eventos relevantes

# Contenidos

**1: Introducción**

**2: Dial a ride: Formulación del Problema**

**3: Dial a ride: Modelación**

**4: Buses: Formulación del problema**

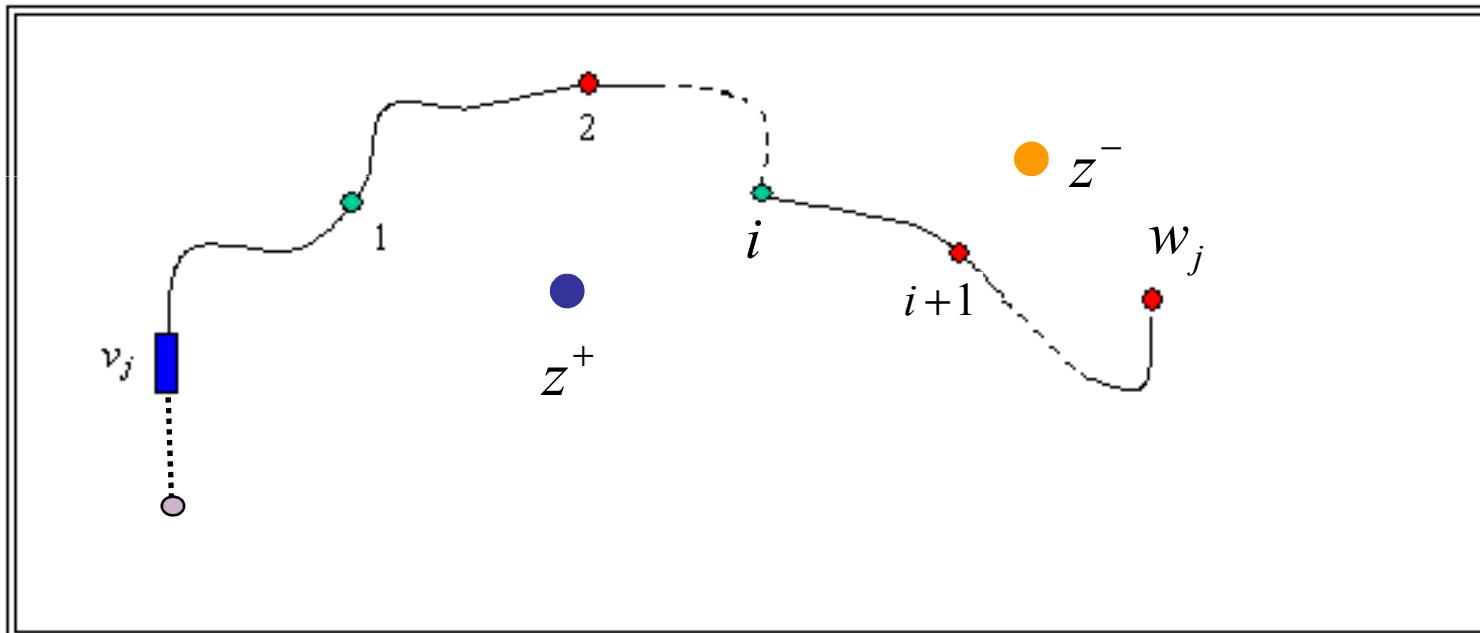
**5: Buses: Modelación**

**6: Conclusiones**

# Introducción.- Control Predictivo Híbrido (HPC)

## ■ Enfoque de HPC: por qué se necesita este enfoque?

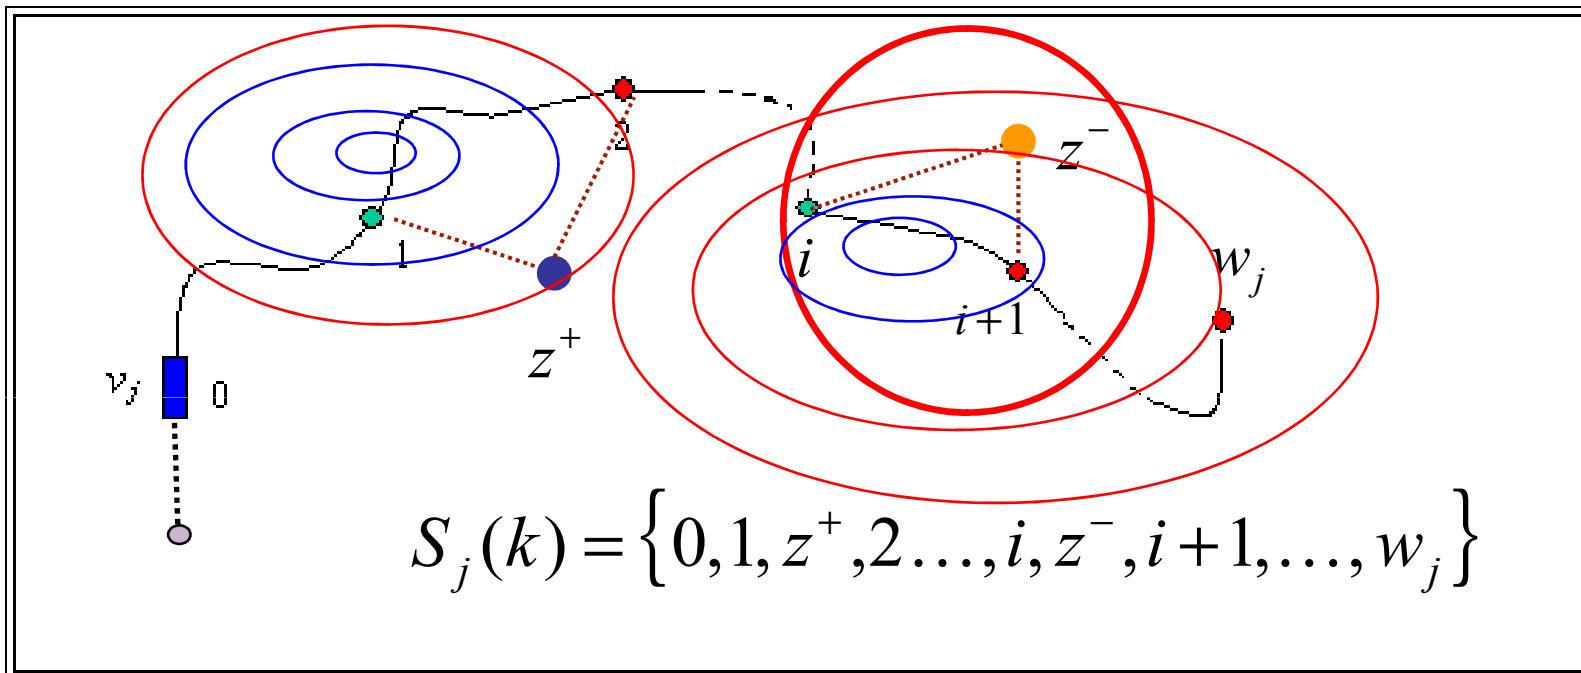
- Considere evento en el instante  $k$  :  $(z^+, z^-)$



**Secuencia:**  $S_j(k-1) = \{0, 1, \dots, i, i+1, \dots, w_j\}$

# Introducción.- Control Predictive Híbrido (HPC)

- Suponga que la nueva llamada se asigna al veh j:



Notar que el tiempo de viaje del segmento (i,i+1)  
aumentó

$$T_j^{i,i+1}(k+1) = T_j^{i,z^-}(k+1) + T_j^{z^-,i+1}(k+1)$$

# Introducción.- Control Predictivo Híbrido (HPC)

El problema tiene una naturaleza dinámica, y entonces el despachador debe tomar decisiones de re-ruteo desconocidas.

Problema: Función de Costos Determinístico no considera costos de re-ruteo futuros reales. Una asignación podría cambiar los re-ruteos futuros y su costo extra asociado.

*Solución: Predecir de mejor manera los tiempos efectivos de viaje*

**Se considerarán dos fuentes de incerteza: la demanda y las condiciones de tráfico**

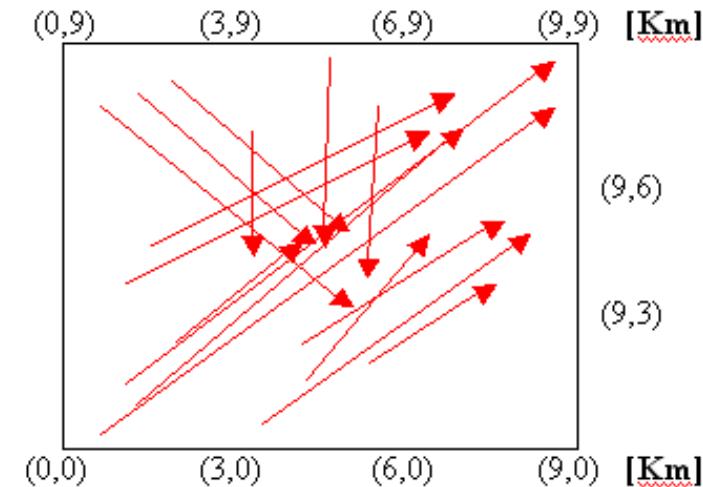
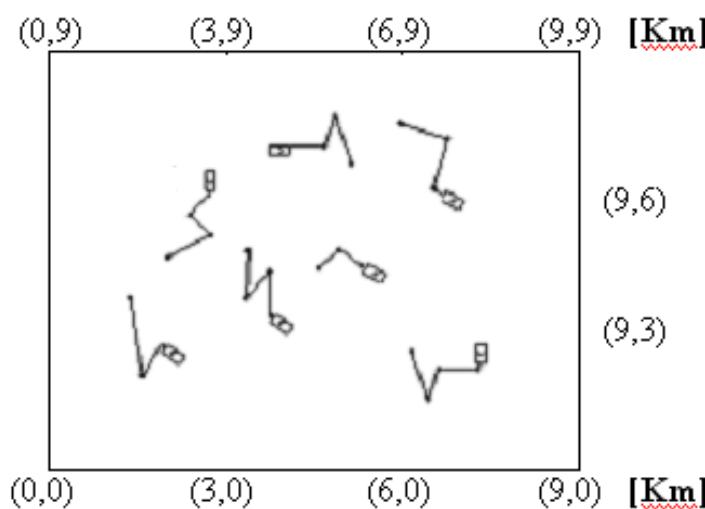
La función de costos ocupada para despachar, incluye predicciones obtenidas con el modelo dinámico durante un horizonte de predicción ( $k+1, k+2, \dots, k+N$ ).

La acción de control solo se aplica en el instante  $k$  (rolling horizon).

# Dial a ride: Formulación del Problema

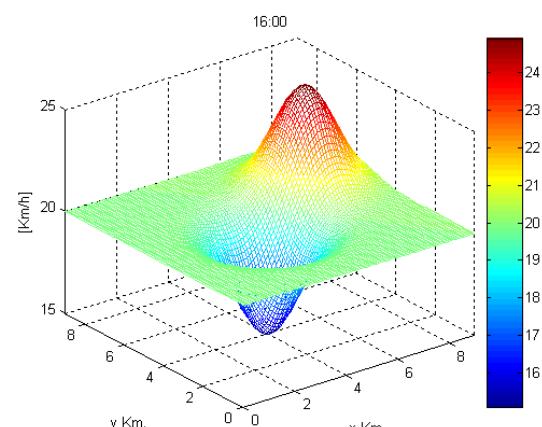
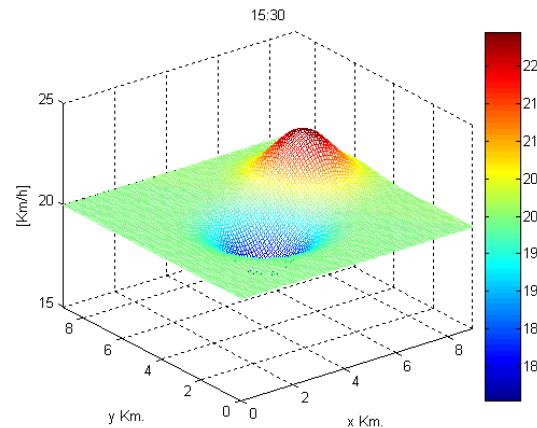
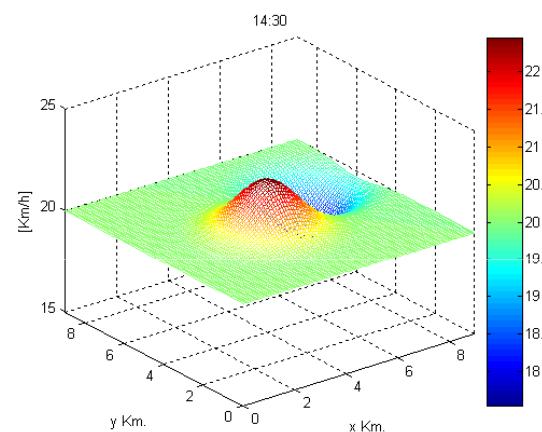
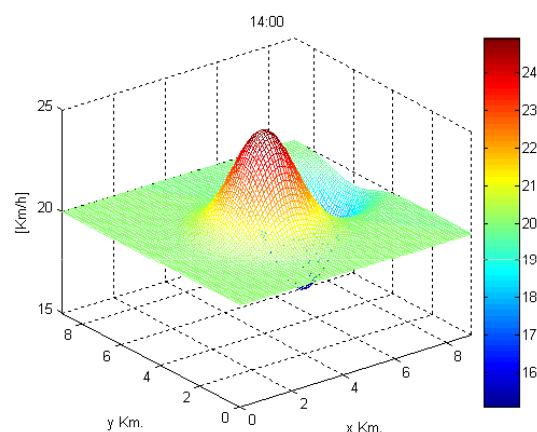
## ■ Data:

- ◆ Área urbana de servicio A (en el ejemplo A es de 81[Km<sup>2</sup>])
- ◆ Conjunto de vehículos V de tamaño F. (en el ejemplo F=9)
- ◆ Tasa histórica de demanda  $\mu$  [calls/minute].
- ◆ Data histórica de llamadas en cada intervalo (coordenadas de recogidas y entregas que se asumen conocidas).
- ◆ Y además .....



# Dial a ride: Formulación del Problema

- Data:
- Distribución Histórica de velocidades en el área urbana



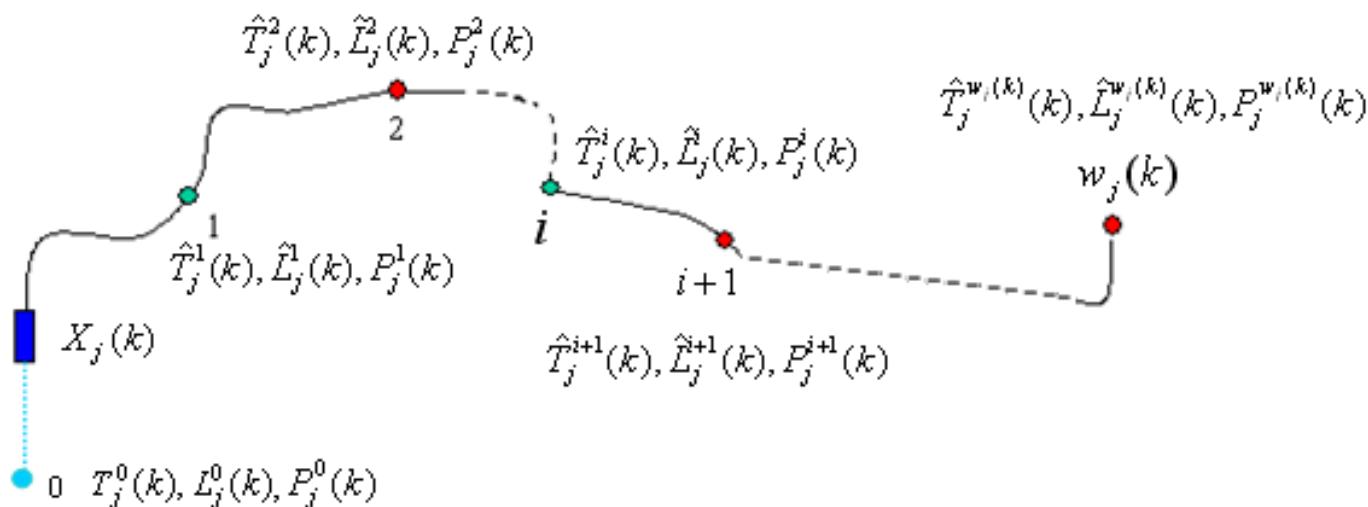
# Dial a ride: Modelación en Variables de Estado

- **Variables de estado consideradas: tiempos de salida estimados, carga entre paradas estimadas, y posición de los vehículos.**

$$\hat{T}_j(k) = \begin{bmatrix} T_j^0(k) & \hat{T}_j^1(k) & \dots & \hat{T}_j^{w_j(k)}(k) \end{bmatrix}_{w_j(k)+1}^T$$

$$\hat{L}_j(k) = \begin{bmatrix} L_j^0(k) & \hat{L}_j^1(k) & \dots & \hat{L}_j^{w_j(k)}(k) \end{bmatrix}_{w_j(k)+1}^T$$

$$X_j(k) \in \square^2$$



# Dial a ride: Modelación. Variable manipulada

---

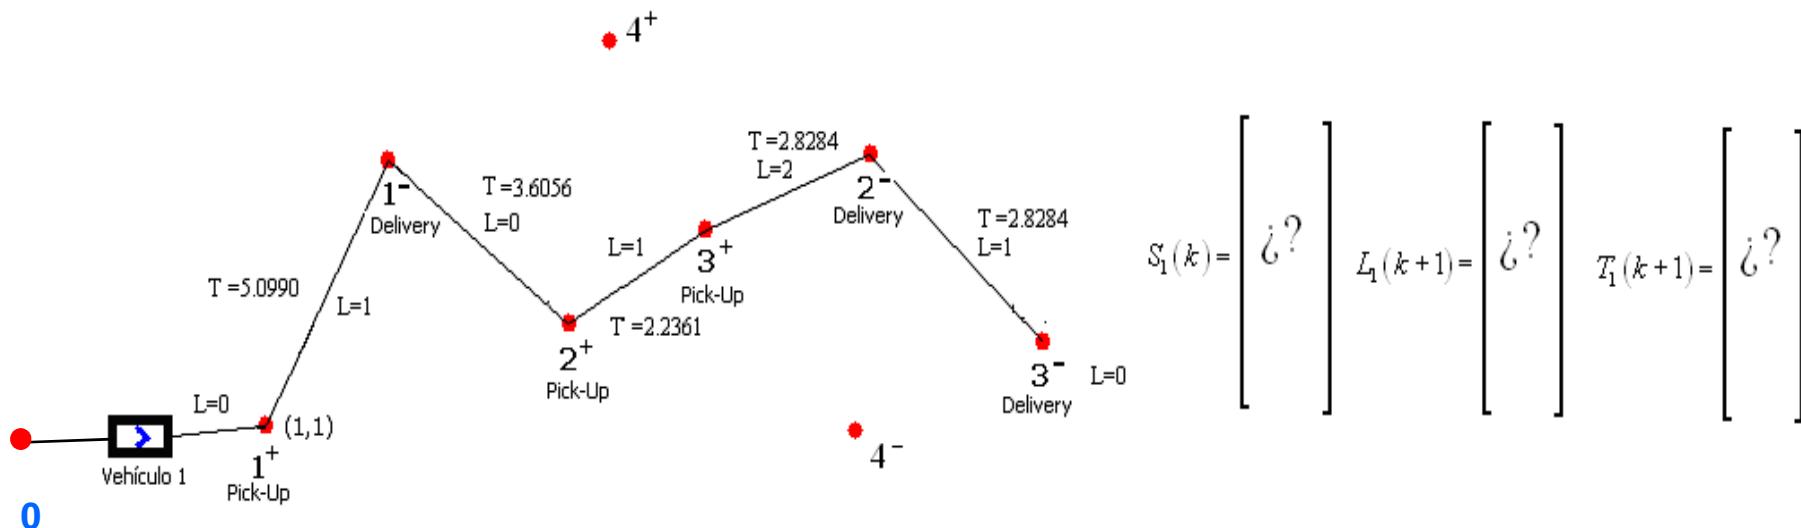
- **Variables de entrada (o de decisión) tomadas por el despachador (controlador) son las secuencias.**

$$u(k) = S(k) = \{S_1(k), \dots, S_j(k), \dots, S_F(k)\}$$

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

# Dial a ride: Modelación. Perturbaciones

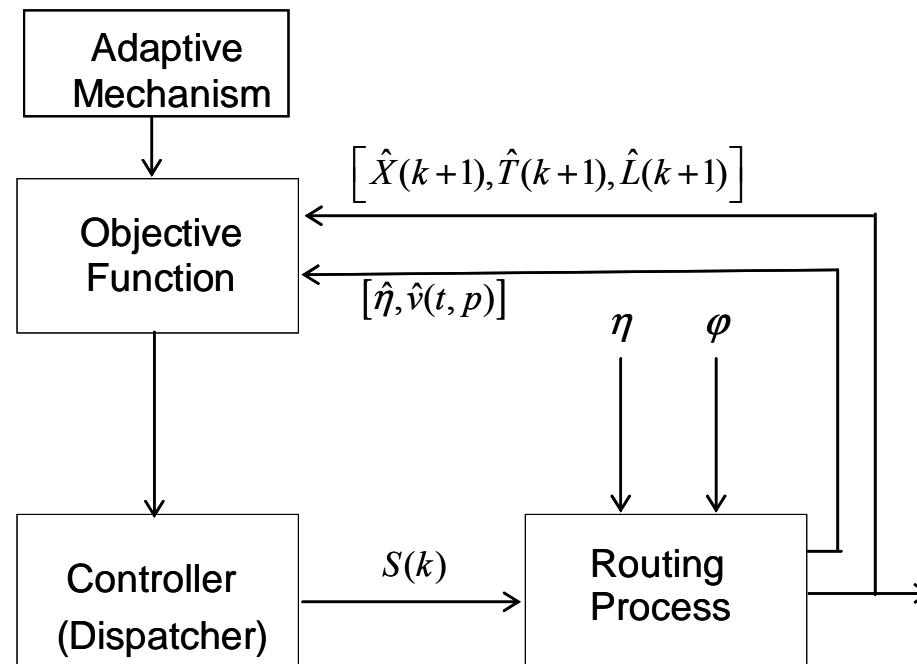
- Nuevos requerimientos y condiciones del tráfico son perturbaciones debido a que no son variables manipuladas.
- El controlador toma la decisión  $S(k)$  basado en una función objetivo. Esta función considera el costo extra asociado a potenciales reruteos que aparecen por requerimientos futuros desconocidos y condiciones esperadas de tráfico



# Dial a ride: Modelación. Ecuaciones de Estado

- Ecuaciones para la evolución de posición, carga y tiempo de llegada cuando se aplica la entrada  $S(k)$ .

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



# Dial a ride: Modelación. Ecuaciones de Estado

$$\hat{T}_j(k+1) = f_T \left( X_j(k), \hat{v}(t, p), \hat{T}_j(k), S_j(k) \right) =$$

$$\begin{bmatrix} T_j^0(k) & t_k + K_j^1(k) & t_k + \sum_{s=1}^2 K_j^s(k) & \cdots & t_k + \sum_{s=1}^{w_j(k)} K_j^s(k) \end{bmatrix}^T_{w_j(k) \times 1}$$

$$K_j^1(k) = \int_{X_j(k)}^{P_j^1(k)} \frac{1}{\hat{v}(t_j(\omega), \omega)} d\omega$$

$$K_j^i(k) = \int_{P_j^{i-1}(k)}^{P_j^i(k)} \frac{1}{\hat{v}(t_j(\omega), \omega)} d\omega$$

$$i = 2..w_j(k)$$

# Dial a ride: Modelación. Ecuaciones de Estado

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

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

# HPC: Función Objetivo

- Para considerar potenciales reruteos debido a requerimientos futuros desconocidos y condiciones de tráfico futuro, se considera una mejor estimación de los tiempos de espera y viaje en la función objetivo asociada al siguiente problema de optimización:

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

con

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

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

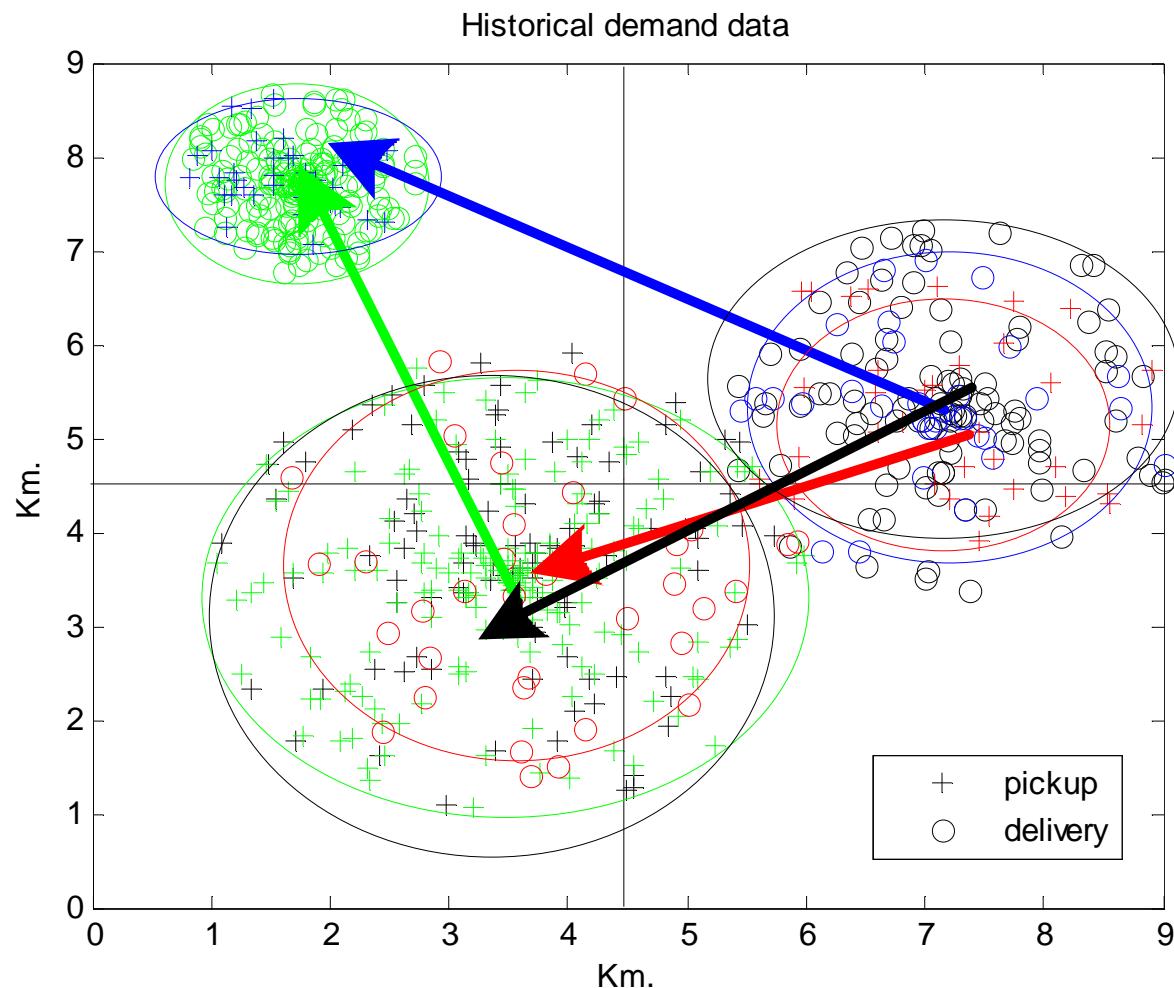
donde

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

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

# Dial a ride: Modelación Demanda

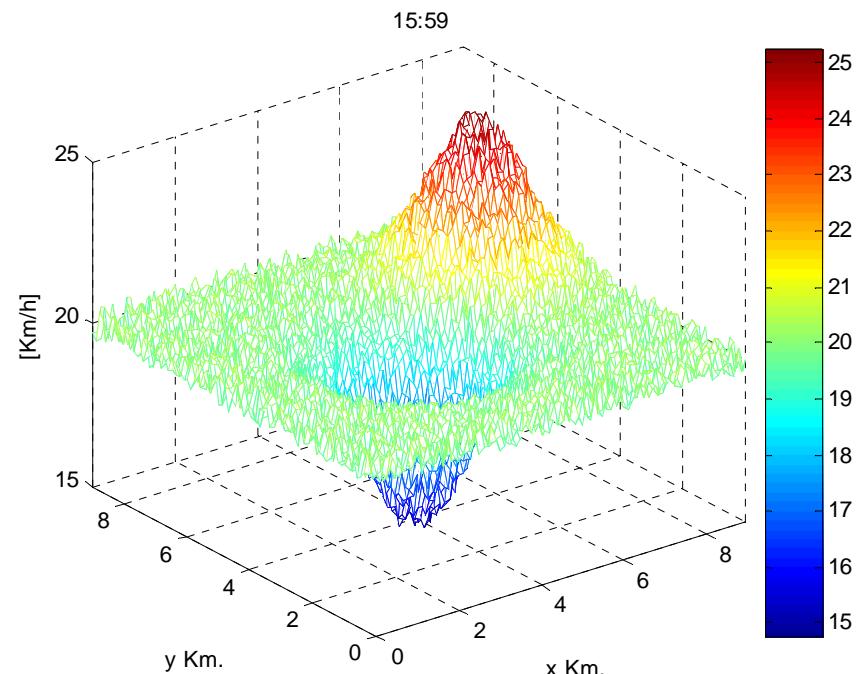
- Demanda histórica es usada para obtener “patrones de viaje”. Cada patrón de viaje tiene una probabilidad asociada y una coordenada origen-destino. Se ocupó un método de zonificación Difusa.



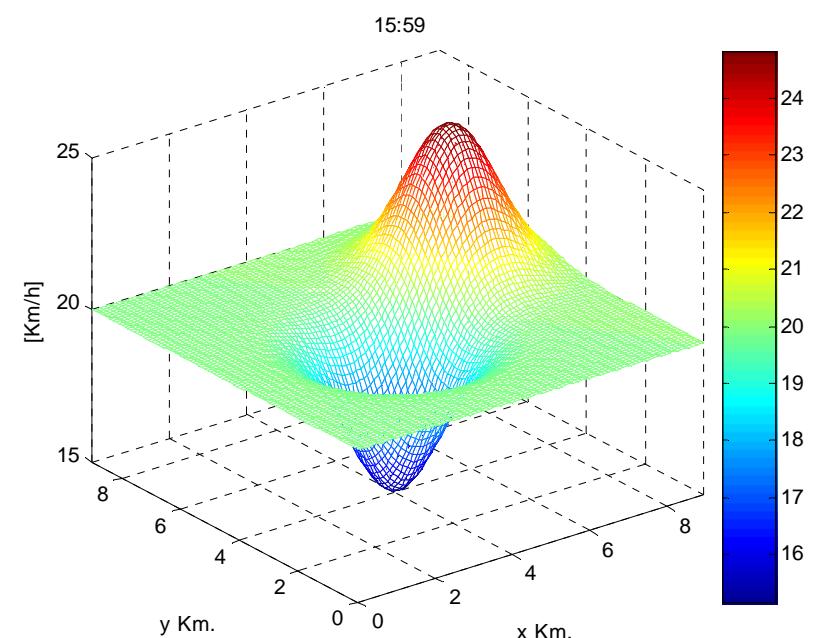
# Dial a ride: Modelación

- Con data histórica se obtiene “distribución de velocidades”.

Real speed distribution



Model speed distribution

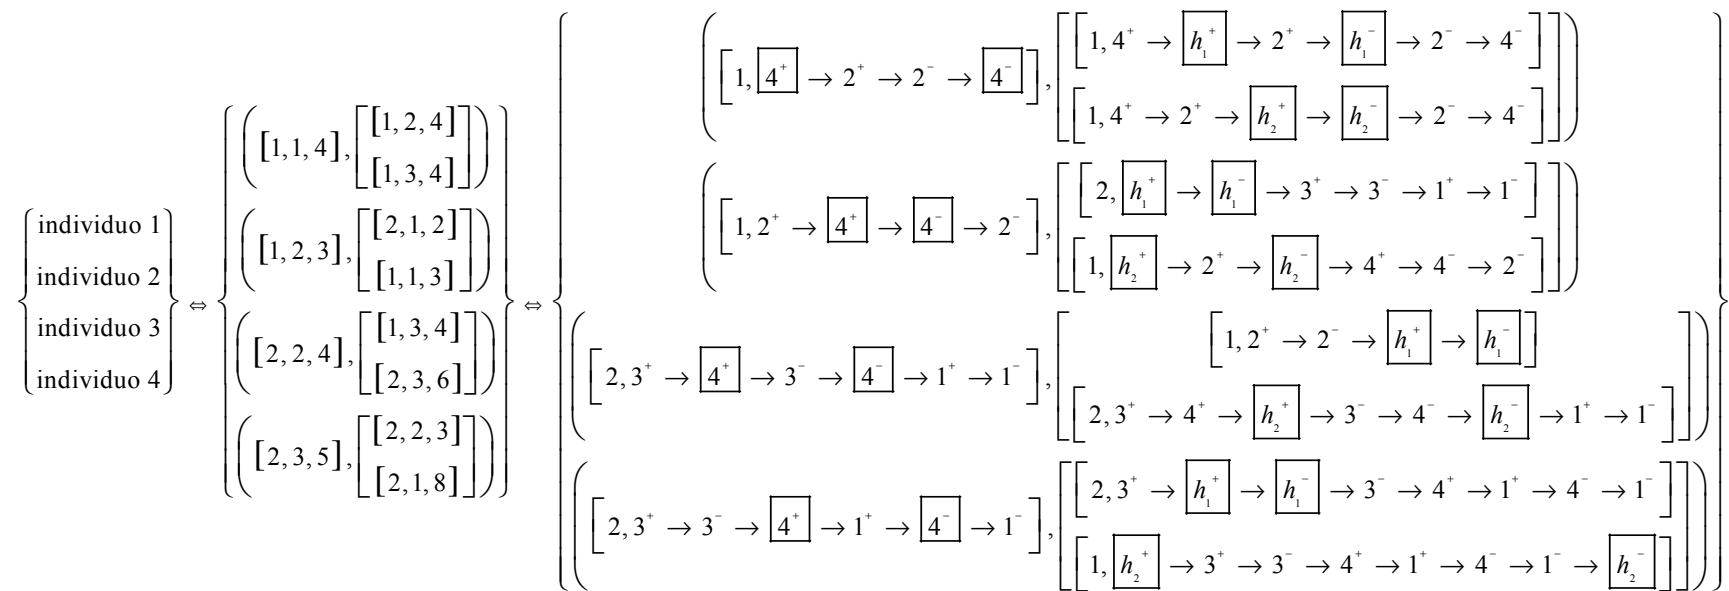


# Control Predictivo Híbrido

## ■ Problemas del algoritmo:

Enumeración explícita no es eficiente para el problema de un solo vehículo. No es factible para  $F$  vehículos y un horizonte  $N_{pred}$  de predicción.

## SOLUCIÓN: Genetic Algorithm



También se disminuye el tiempo computacional realizando la búsqueda de soluciones en un subespacio factible que satisfacen restricción de “NO SWAPPING”, la cual considera la secuencia óptima previa.

# Multiobjetivo para el problema de ruteo

---

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

**Solución corresponde a un conjunto de secuencias de control que forman el conjunto de Pareto Óptimo. Sea  $S^i = \{S^i(k), \dots, S^i(k+N_u-1)\}$  secuencia factible de acciones de control**

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

$$(J_1(S^i) \leq J_1(S^j) \wedge J_2(S^i) < J_2(S^j)) \vee (J_2(S^i) \leq J_2(S^j) \wedge J_1(S^i) < J_1(S^j))$$

- $S^i$  se dice Pareto Óptima si y solo si no existe otra solución  $S^j$  que la domine según el criterio anterior.

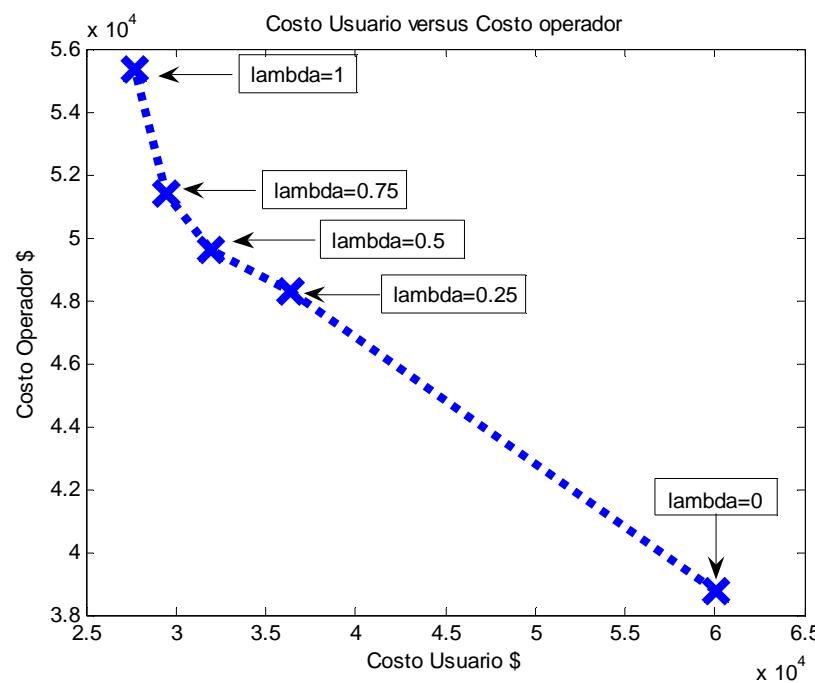
-El conjunto de Pareto Óptimo  $P_s$  contiene todas las soluciones Pareto Óptima.

-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:

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

# Multiobjetivo para el problema de ruteo

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

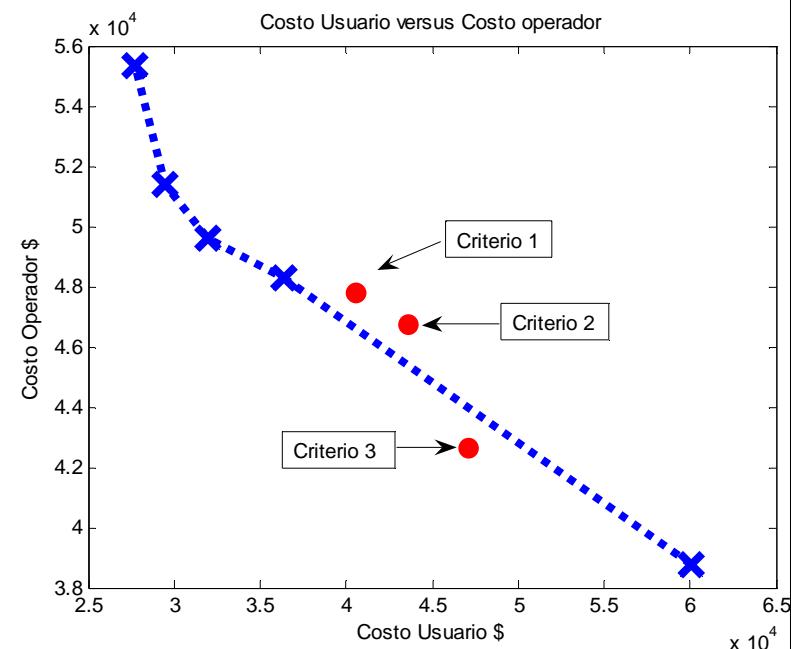


# Resultados Multiobjetivo:

Con HAPC-EMO fue posible fijar políticas de servicio (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

*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*



# Resultados Congestión Predecible

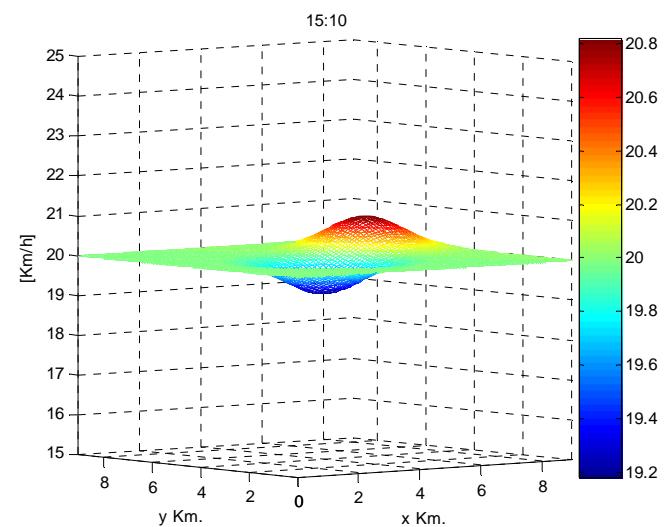
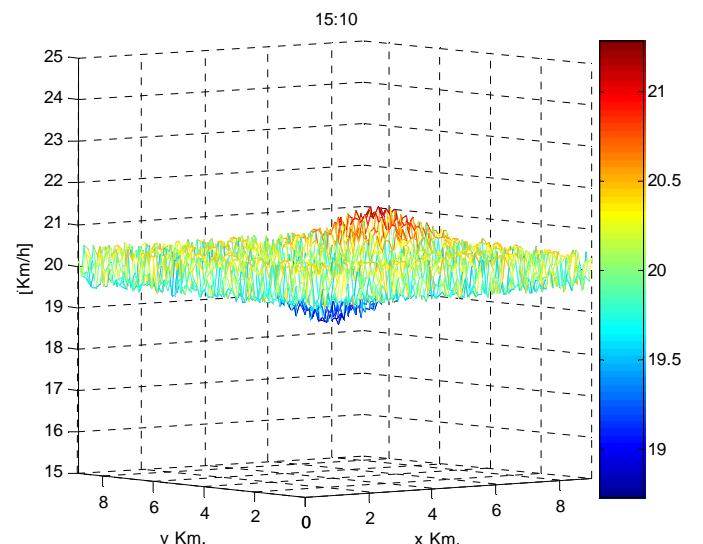
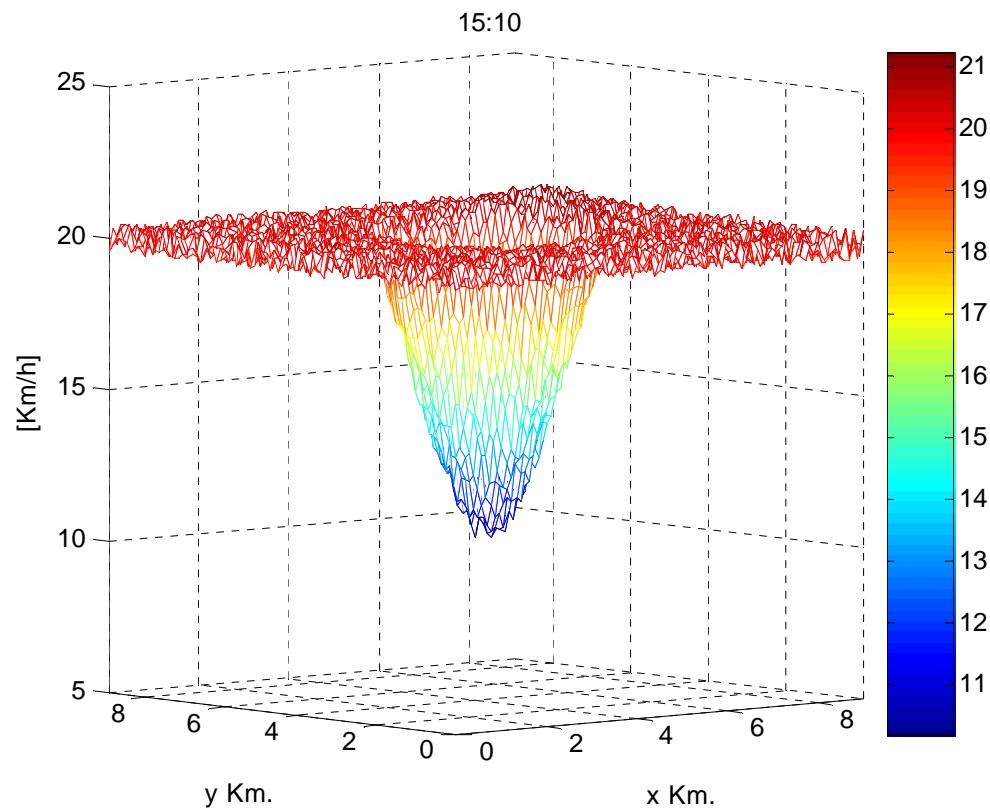
Comparación uno y dos pasos.  
Estimación con velocidad variable en el tiempo.

Variable Velocity estimation	waiting time (min)		travel time (min)		Total time (min)	
	Mean	Std	Mean	Std	Mean	Std
<b>One Step Ahead</b>	15.443	1.64	17.879	0.61	33.322	1.71
<b>Two Step Ahead</b>	13.618	1.90	16.939	0.65	30.558	2.36
<b>Savings 2 step</b>	1.8243		0.9402		2.7645	
<b>Improv. (%)</b>	<b>11.81%</b>		<b>5.26%</b>		<b>8.30%</b>	

	waiting time (min)	travel time (min)	Total time (min)
<b>Savings velocity 1 step</b>	0.4019	0.4661	0.8680
<b>Improv. (%)</b>	<b>3.54%</b>	<b>2.54%</b>	<b>2.85%</b>
<b>Savings velocity 2 step</b>	0.4591	0.0628	0.5220
<b>Improv. (%)</b>	<b>3.26%</b>	<b>0.37%</b>	<b>1.68%</b>

# Congestión impredecible

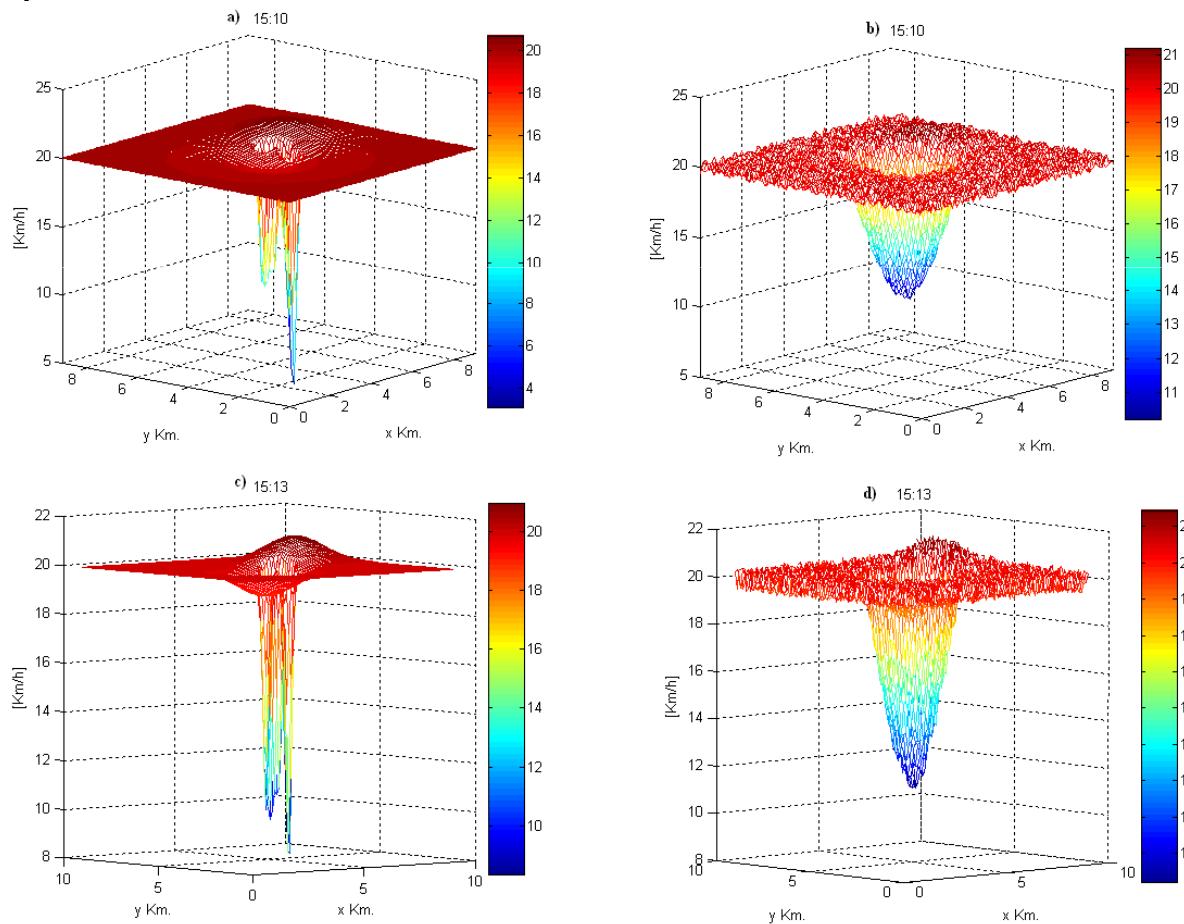
Suponga que ocurre un incidente que afecta la distribución de velocidades



# Detector y aislador de falla, y control tolerante a falla difuso (FDI-FFTC)

## ■ Procedimiento:

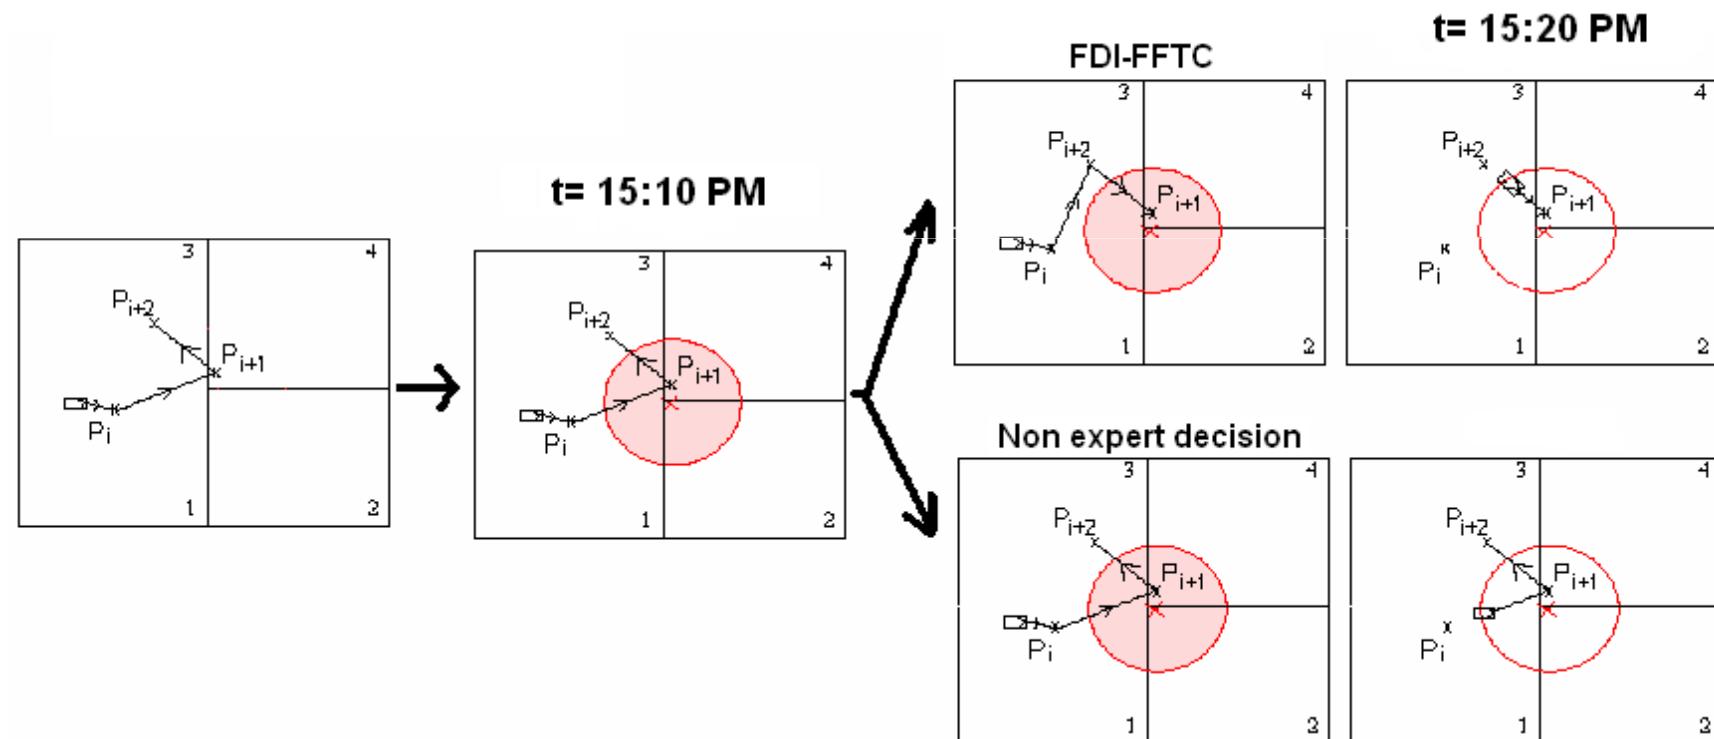
- ◆ Cuando algún vehículo detecta el incidente durante un cierto periodo de tiempo, ocupando una base de reglas difusa se genera un modelo que incluye el incidente. Este modelo intenta representar el efecto del evento inesperado.



# FDI-FFTC

## ■ Procedimiento:

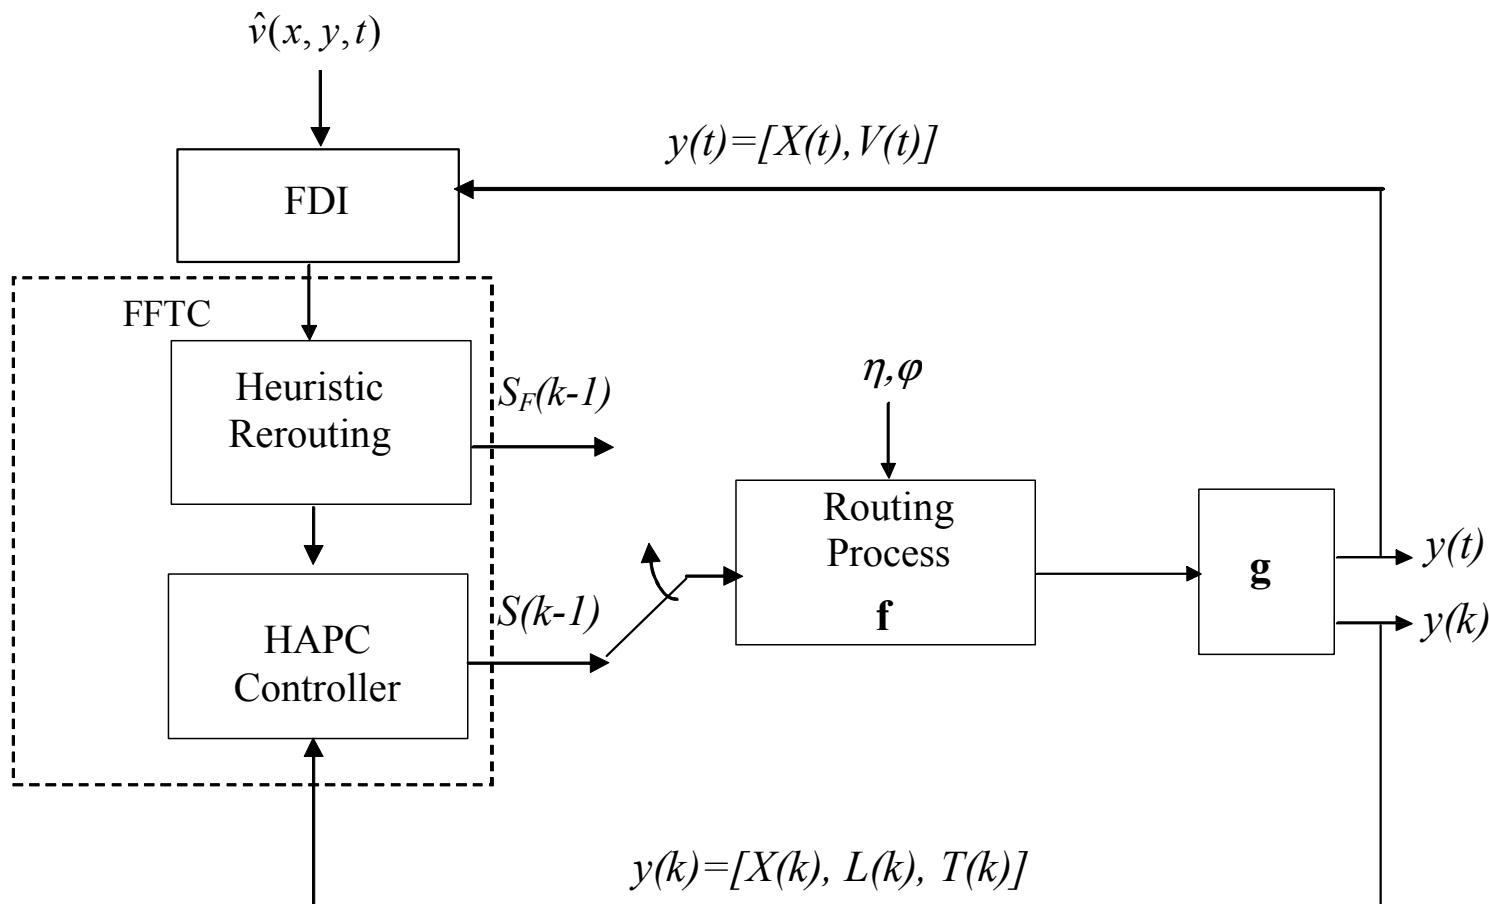
- ◆ Requerimientos ubicados dentro de la zona crítica son re-asignados como nuevas llamadas por el despachador basados en HAPC, pero considerando el modelo con el incidente.



# FDI-FFTC

## ■ Procedimiento:

- ◆ Después de re-rutear, las nuevas llamadas son asignadas basados en HAPC considerando el nuevo modelo recurrente con incidente.



# Resultados FDI-FFTC

**Case 1: HAPC usando un modelo recurrente para velocidades en función del tiempo y espacio**

**Case 2: HAPC usando FDI-FFTC**

**Case 3: HAPC usando un modelo que conoce por completo la falla.**

	waiting time (min)	travel time (min)	Total time (min)	Operation cost (min)	Effective total cost (min)
	Mean	Mean	Mean	Mean	Mean
<b>Case 1</b>	9.5110	12.6994	22.2104	132.3360	687.3965
<b>Case 2</b>	7.9461	12.9906	20.9367	132.0360	659.7205
<b>Improv. (%)</b>	<b>16.45%</b>	<b>-2.3%</b>	<b>5.73%</b>	<b>0.2%</b>	<b>4.01%</b>
<b>Case 3</b>	8.1758	11.8525	20.0283	131.9050	632.6113
<b>Improv. (%)</b>	<b>2.42%</b>	<b>-8.96%</b>	<b>-4.09%</b>	<b>-0.1%</b>	<b>-3.94%</b>

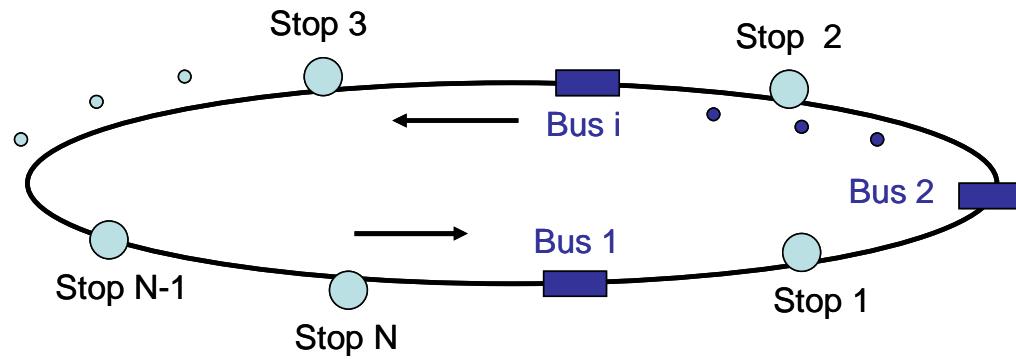
# Sistema de transporte público de ruta fija

- Tiempos de Espera: Son directamente proporcionales a la magnitud de los intervalos entre los buses del mismo recorrido.
- Tiempos de Viaje: Se ven afectados por tanto por las perturbaciones del sistema como las acciones que sobre éste se pueden tomar.
- Objetivo: Desarrollo de estrategias de Control Predictivo Híbrido para regulación de intervalos entre buses de cada recorrido
  - ◆ Formulación, desarrollo, simulación, validación

# Transit network

- The model consists on:

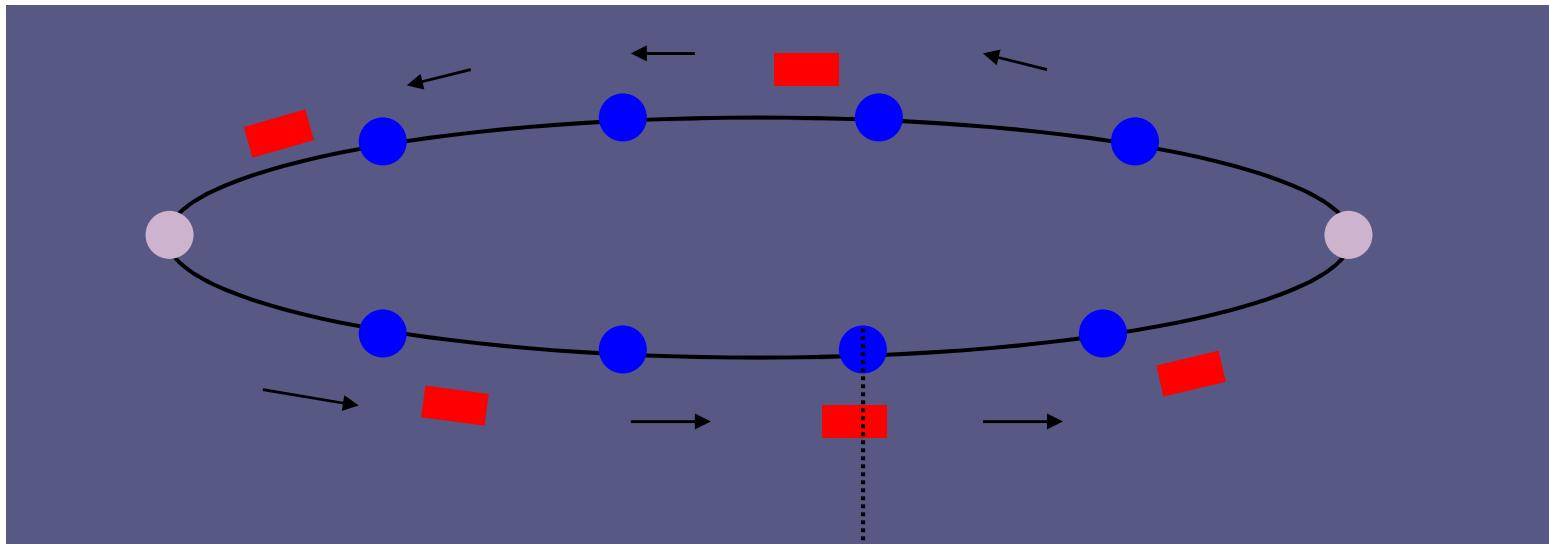
- ◆ b buses
- ◆ n stations
- ◆ Disturbances



- Control actions
  - ✓ Holding
  - ✓ Station skipping

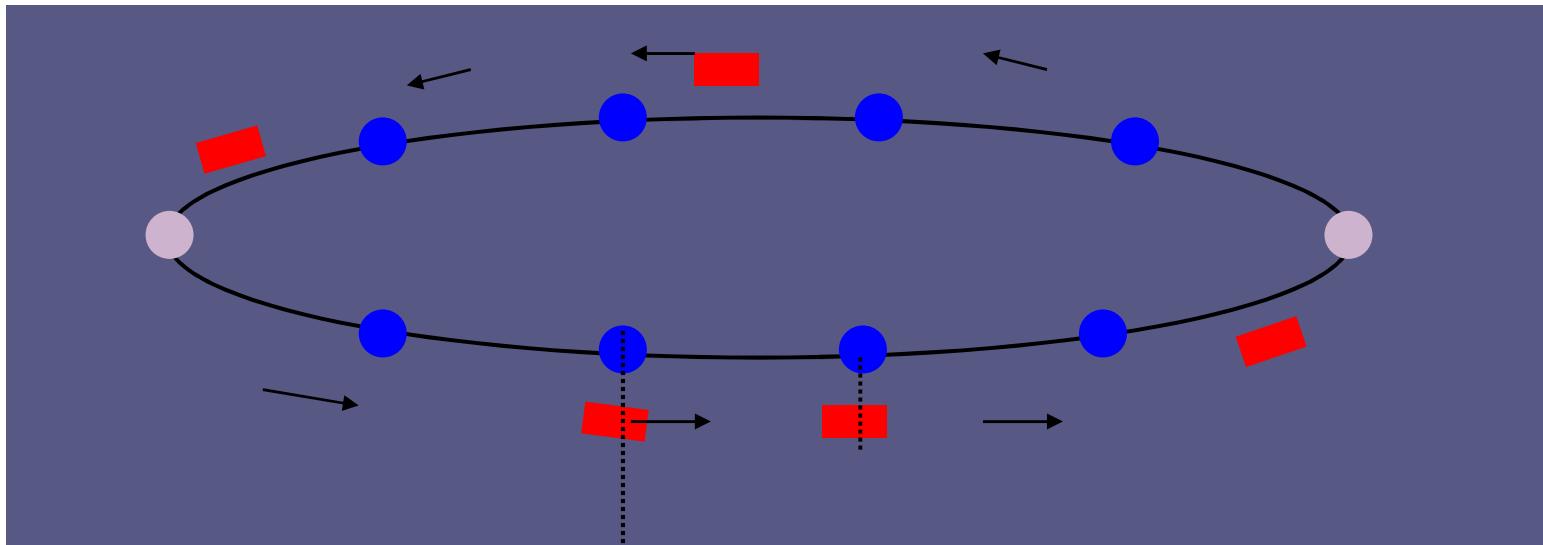
# Simulación de Eventos

(llegada de buses a un paradero o un semáforo)



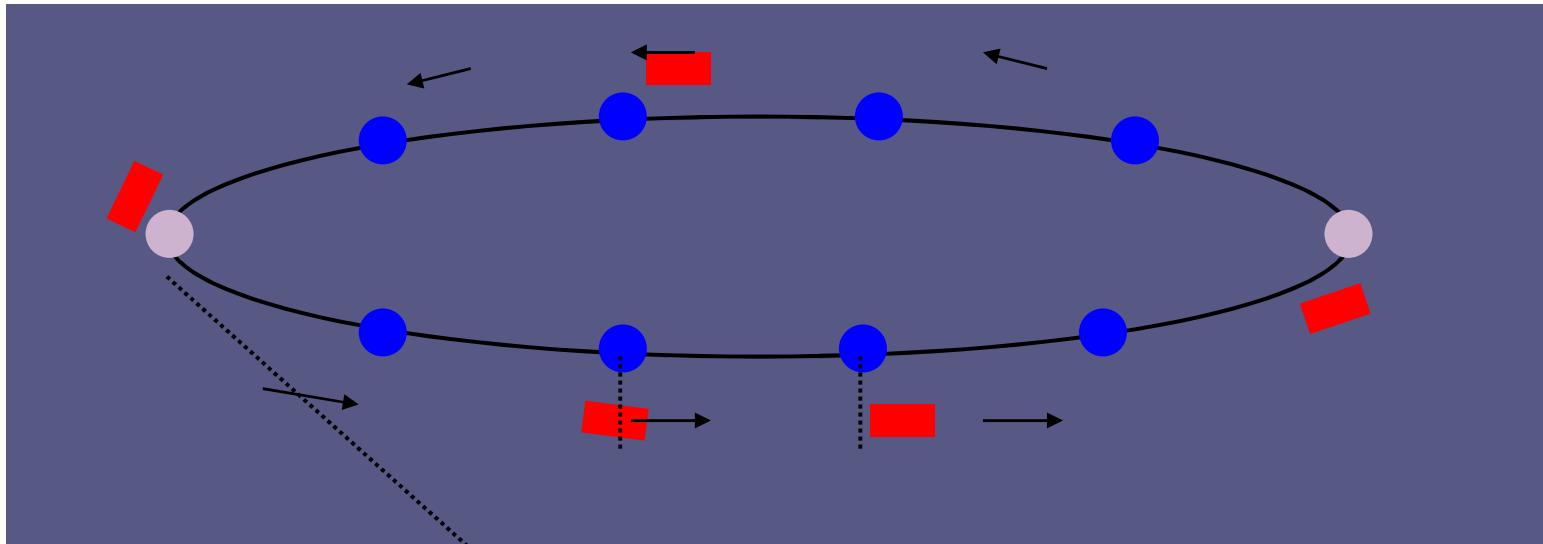
Se define instante  $k$

# Simulación de Eventos



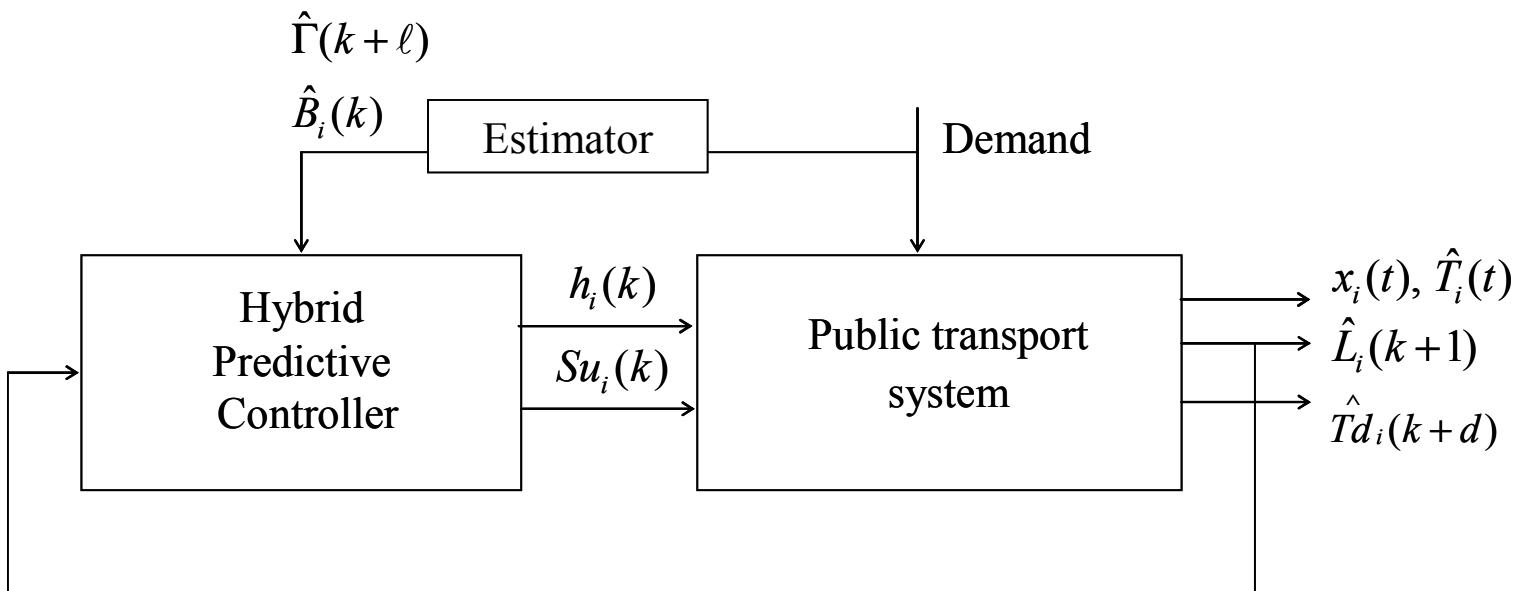
Se define instante  $k+1$

# Simulación de Eventos



Se define instante  $k+2$

# Hybrid Predictive Control Scheme



$\hat{L}_i(k+1)$  : Load of bus  $i$  at instant  $k$

$\hat{T}_d(k+d)$  : Estimated departure time of bus  $i$  at instant  $k$

$h_i(k)$  : Holding action of bus  $i$  at instant  $k$

$Su_i(k-1)$  : Passenger boarding action of bus  $i$  at instant  $k-1$

$x_i(t)$  : Position of bus

$\hat{T}_i(t)$  : Remaining time for bus  $i$  to reach the next stop

$\hat{B}_i(k)$  : Estimated boarding passengers

$\hat{\Gamma}_i(k+\ell)$  : Estimated stop load at instant  $k+\ell$

# Dynamic modeling:

## State space variables

- ◆ Position of bus  $i$

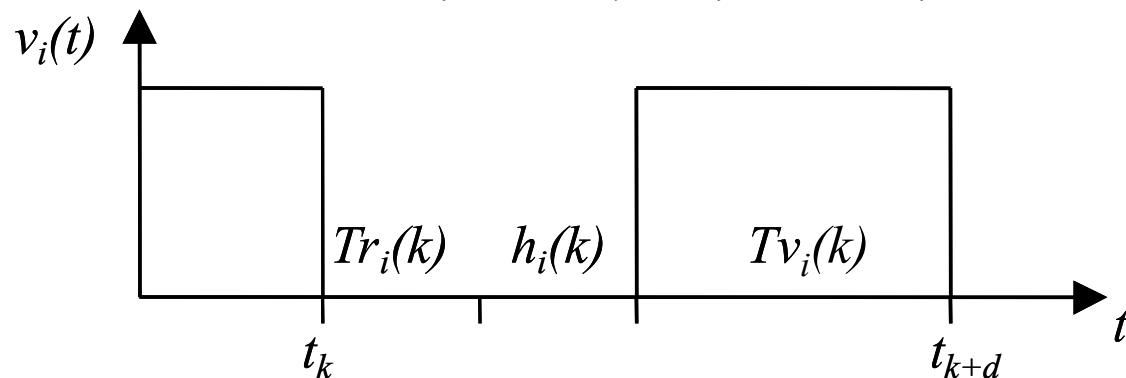
$$x_i(t) = x_i(t_k) + \int_{t_k}^t v_i(\vartheta) d\vartheta$$

- ◆ Velocity of bus  $i$

$$v_i(t) = \begin{cases} 0 & t_k \leq t \leq t_k + h_i(k) + Tr_i(k) \\ v_0 & t_k + h_i(k) + Tr_i(k) \leq t \leq t_{k+d} \end{cases}$$

- ◆ Remaining time for the bus  $i$  to reach the next stop

$$T_i(t) = t_k + h_i(k) + Tr_i(k) + T v_i - t$$



## Dynamic modeling:

### Output variables

- ◆ Departure time of bus i

$$\hat{Td}_i(k + \ell) = t_k + h_i(k) + Tr_i(k)$$

- ◆ Load of bus i

$$\hat{L}_i(k + \ell) = L_i(k) + \hat{B}_i(k)Su_i(k) - A_i(k)$$

- ◆ Bus stop load

$$\hat{\Gamma}(k + \ell) = \Gamma(k) + \hat{\delta}_p(k, k + \ell) - B_{i-1}(k)$$

- ◆ Headway of bus  $i$  at the station reached when event happens

$$\hat{H}_i(k + \ell) = \hat{Td}_i(k + \ell) - \hat{Td}_{i-1}(k + \ell - z)$$

# Objective function

Quantifies the average passenger waiting time in a stop

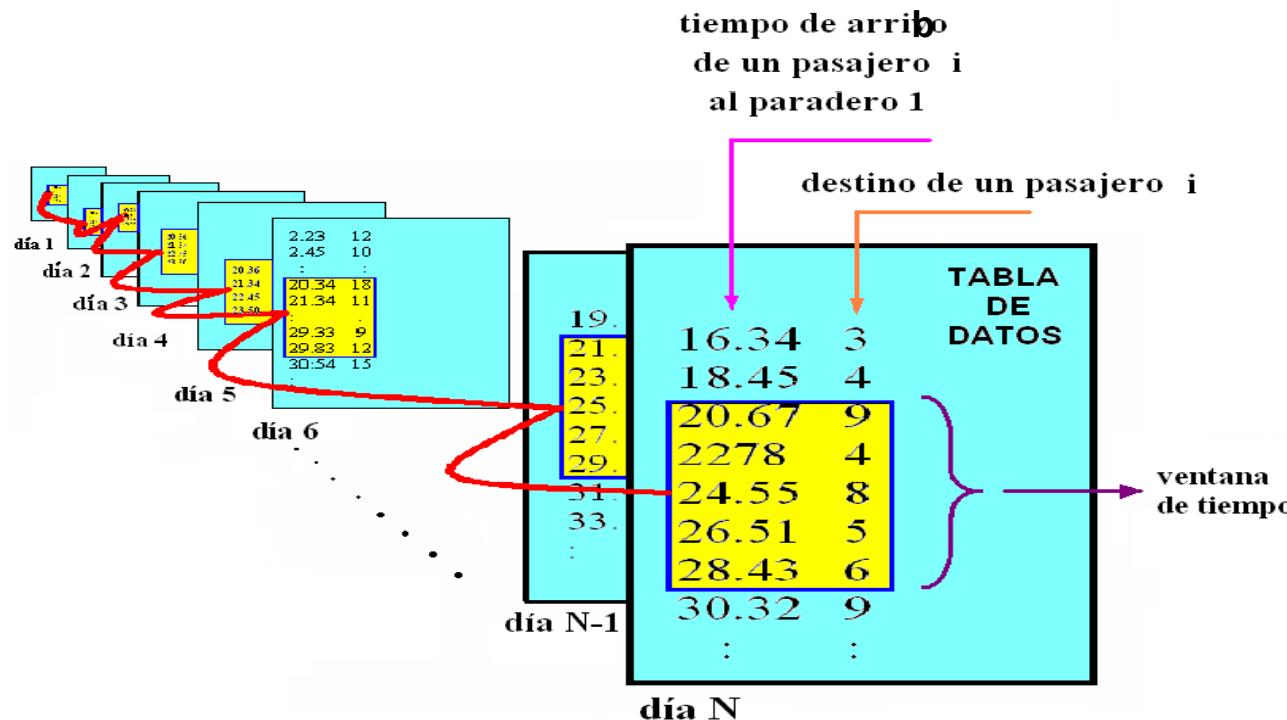
To regularize bus headway

$$\underset{u(k)=\{h(k) \text{ } Su(k)\}}{\text{Min}} \quad J = \sum_{\ell=1}^{N_p} \sum_{i=1}^b \left[ \theta_1 \cdot \hat{H}_i(k+\ell) \hat{L}_s(k+\ell) + \theta_2 \cdot (\hat{H}_i(k+\ell) - \bar{H})^2 + \right. \\ \left. + \theta_3 \cdot \hat{L}_i(k+\ell) h_i(k+\ell-1) + \theta_4 \cdot \hat{L}_s(k+\ell) \hat{H}_{i+1}(k+\ell+z) (1 - Su_i(k+\ell-1)) \right]$$

Extra waiting time of passengers for the holding time of a bus

Waiting time of passengers whose station is skipped by an expressed vehicle

# Estimación de la demanda origen destino



# Genetic Algorithm Solution

Manipulated variables:

- Holding action 0, 30, 60 and 90 [s] at the selected bus stops.
- Station skipping . “0” value when the bus skips the stop and “1” otherwise

$$u(k) \in \left\{ \begin{bmatrix} 0 \\ 1 \end{bmatrix}, \begin{bmatrix} 30 \\ 1 \end{bmatrix}, \begin{bmatrix} 60 \\ 1 \end{bmatrix}, \begin{bmatrix} 90 \\ 1 \end{bmatrix}, \begin{bmatrix} 0 \\ 0 \end{bmatrix} \right\}$$

• GA codification

$$\boxed{1} = \begin{bmatrix} 0 \\ 1 \end{bmatrix}, \boxed{2} = \begin{bmatrix} 30 \\ 1 \end{bmatrix}, \boxed{3} = \begin{bmatrix} 60 \\ 1 \end{bmatrix}, \boxed{4} = \begin{bmatrix} 90 \\ 1 \end{bmatrix}, \boxed{5} = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

# Genetic Algorithm Solution

## ■ Population of individuals

$$\text{Population } i \Leftrightarrow \begin{pmatrix} \text{Individual 1} \\ \text{Individual 2} \\ \vdots \\ \text{Individual n} \end{pmatrix} \Leftrightarrow \begin{pmatrix} 1|1|2|3|5 \\ 2|1|3|3|4 \\ \vdots \\ 4|5|1|2|3 \end{pmatrix}$$

Example    Individual 1 =  $\begin{bmatrix} u(k) & u(k+1) & u(k+2) & u(k+3) & u(k+4) \end{bmatrix}^T$

$$= \begin{bmatrix} 1 & 1 & 2 & 3 & 5 \end{bmatrix}^T = \begin{bmatrix} 0 & 0 & 30 & 60 & 0 \\ 1 & 1 & 1 & 1 & 0 \end{bmatrix}$$

## ■ Conventional GA based on defined objective function

# Simulation tests

- The simulation parameters are
  - ◆ 6 buses.
  - ◆ Demand with known arrival rates to stations.
  - ◆ 10 equidistant stations with one holding station.
  - ◆ Constant bus velocity between stations.

# Simulation tests

Weight Factors θ1–θ2–θ3–θ4	Prediction Horizon	Waiting Time [min]	Travel Time [min]	Total Time [min]
Open Loop		9.26	9.60	18.87
1-1-0-0	Np=2	5.49	9.41	14.90
	Np=5	5.69	9.40	15.09
	Np=10	5.78	9.70	15.48
1-1-0.005-0	Np=2	7.22	9.62	16.83
	Np=5	5.12	9.67	14.79
	Np=10	5.79	9.80	15.59
1-1-1-0	Np=2	5.44	9.54	14.98
	Np=5	5.00	9.83	14.83
	Np=10	4.91	9.76	14.67
1-1-0-1	Np=2	6.09	10.03	16.12
	Np=5	6.08	10.32	16.40
	Np=10	7.14	10.01	17.15
1-1-0-10	Np=2	6.09	10.03	16.12
	Np=5	6.59	10.19	16.79

45% of saving in waiting time

20% of saving in total time.

# Simulation tests

Weight Factors	Holding 30[s]		Holding 60[s]		Holding 90[s]		Station Skipping		Total Pax
	Pax	Number	Pax	Number	Pax	Number	Pax	Number	
01-02-03-04									
1-1-0-0	0	0	13	1	277	17	92	20	1292
	32	1	13	1	355	17	179	21	1385
	125	2	7	1	473	12	142	18	1404
1-1-0.005-0	26	2	0	0	18	3	91	29	1399
	0	1	14	2	6	2	221	50	1202
	139	3	117	4	86	4	76	29	1354
1-1-1-0	0	0	0	0	0	2	94	31	1214
	0	0	0	0	0	0	16	33	1276
	0	0	0	0	0	0	105	25	1406
1-1-0-1	0	0	63	1	288	16	78	25	1219
	12	1	121	3	348	7	156	35	1317
	22	1	92	4	371	9	46	25	1343
1-1-0-10	0	0	68	2	276	15	78	25	1219
	82	4	138	4	376	8	43	21	1403
	196	4	98	4	163	5	30	30	1355

# Simulation tests

Weight Factors $\theta_1-\theta_2-\theta_3-\theta_4$	%Ph	%PSk	av(h1) [min]	av(h2) [min]
1-1-0-0	22	7	0.33	88.66
	29	13	0.41	84.23
	43	10	0.55	77.26
1-1-0.005-0	3	7	0.03	54.55
	2	18	0.02	69.00
	25	6	0.23	55.35
1-1-1-0	0	8	0.00	0.00
	0	1	0.00	0.00
	0	7	0.00	0.00
1-1-0-1	29	6	0.41	84.62
	37	12	0.49	80.96
	36	3	0.49	81.59
1-1-0-10	28	6	0.40	84.07
	42	3	0.53	74.80
	34	2	0.33	57.83

# Comentarios y Conclusiones

- Enfoque unificado que permite sistematizar la modelación y solución de problemas dinámicos de transporte
- Control Adaptivo Predictivo Híbrido (HAPC) basado en técnicas de inteligencia artificial (Fuzzy clustering, GA, PSO, etc.)
- La formulación permitió incluir dentro del diseño las predicciones de tanto la demanda futura como de las condiciones de tráfico.
- Dial-a-ride: El enfoque FDI-FFTC mejoró significativamente las reglas de despacho bajo escenarios distorsionados.
- Ruta fija: Resultados preliminares muestran importantes beneficios en ahorros de tiempos de espera y regularización de intervalos
- Aplicación toma importancia debido a desarrollo de tecnologías ITS

# Trabajo en curso y futuro

---

## Dial-a-ride

- Mejores modelos de velocidad y de variados tipos de incidentes.
- Extender la actual formulación para el uso de estaciones de monitoreo de tráfico fijo.
- Actualización on-line de demanda (cambios bruscos de demanda).
- Microsimulación

## TP ruta fija

- Sistemas con trasbordos: Holding en trasbordos, agregar objetivo de minimizar tiempos de espera totales en trasbordos
- Otras estrategias en tiempo real: inyección de vehículos en bucles o deadheading
- Reparto de semáforos de prioridad para transporte público
- Modelos sofisticados de predicción de demanda
- Microsimulación