

# INTRODUCCIÓN A LA PROGRAMACIÓN DE UN AUTOMÓVIL AUTÓNOMO

Taihú Pire

Laboratorio de Robótica  
Facultad de Ciencias Exactas y Naturales  
Universidad de Buenos Aires

1 INTRODUCCIÓN

2 TIPOS DE FILTROS

3 PARTICLE FILTER

## PARTICLE FILTER

Particle Filter es un algoritmo que permite estimar el estado de un sistema.

- Ventajas:
  - Muy fácil de implementar
  - Es el método más flexible
- Desventaja:
  - No es siempre aplicable

## EJERCICIO

- 1 **Espacio de estados:** ¿Sobre qué tipo de espacio de estados trabajan?
- 2 **Modalidad de creencia:** ¿Qué tipo de distribución es utilizada (Unimodal o Multimodal) por los filtros?
- 3 **Eficiencia:** ¿Cuando el número de dimensiones del espacio de estados aumenta, cómo es afectada la representación de la grilla de celdas y la gaussiana para cada filtro?
- 4 **Exactitud:** ¿Los métodos aproximan la distribución a posteriori o son exactos?

Quiz	state space	belief	efficiency	in robotics
Class 1 Histogram Filters	<input type="checkbox"/> Discrete <input type="checkbox"/> Continuous	<input type="checkbox"/> Unimodal <input type="checkbox"/> multimodal	<input type="checkbox"/> quadratic <input type="checkbox"/> exponential	<input type="checkbox"/> exact <input type="checkbox"/> approximate
Class 2 Kalman Filters	<input type="checkbox"/> Discrete <input type="checkbox"/> Continuous	<input type="checkbox"/> Unimodal <input type="checkbox"/> multimodal	<input type="checkbox"/> quadratic <input type="checkbox"/> exponential	<input type="checkbox"/> exact <input type="checkbox"/> approximate

# TIPOS DE FILTROS

QUIZ	state space	belief	efficiency	in robotics
Class 1 Histogram Filters	<input checked="" type="checkbox"/> Discrete <input type="checkbox"/> Continuous	<input type="checkbox"/> unimodal <input checked="" type="checkbox"/> multimodal	<input type="checkbox"/> quadratic <input checked="" type="checkbox"/> exponential	<input type="checkbox"/> exact <input checked="" type="checkbox"/> approximate
Class 2 Kalman Filters	<input type="checkbox"/> Discrete <input checked="" type="checkbox"/> Continuous	<input checked="" type="checkbox"/> unimodal <input type="checkbox"/> multimodal	<input checked="" type="checkbox"/> quadratic <input type="checkbox"/> exponential	<input type="checkbox"/> exact <input checked="" type="checkbox"/> approximate

## OBSERVACIÓN (EFICIENCIA)

- *Histogram Filter*: escala exponencialmente,  $K^D$ , donde  $K$  es la cantidad de celdas y  $D$  el número de dimensiones. Esto se debe a que cada dimensión va a tener asociado un histograma (grilla), y cada celda de un histograma puede “combinarse” con cada una de las celdas del resto de los histogramas.
- *Kalman Filter*: escala cuadráticamente debido a que esta completamente representado por el vector media y la matriz de covarianza que es cuadrática.

# TIPOS DE FILTROS

<u>Quiz</u>	state space	belief	efficiency	in robotics
Class 1 Histogram Filters	<del>Discrete</del> o Continuous	o unimodal <del>multimodal</del>	o quadratic <del>exponential</del>	o exact <del>approximate</del>
Class 2 Kalman Filters	o Discrete <del>Continuous</del>	<del>unimodal</del> o multimodal	<del>quadratic</del> o exponential	o exact <del>approximate</del>
Class 3 Particle Filters	Continuous	multimodal	?	approximate


## OBSERVACIÓN (EFICIENCIA)

- *Particle Filter*: en ciertas situaciones escala **exponencialmente**. En casos donde el espacio es de más de cuatro dimensiones *Particle Filter* no debe ser utilizado. Sin embargo, en problemas de tracking funciona bien.

# EJEMPLO 1: PARTICLE FILTER


## EJEMPLO

- *En la imagen, el robot está ubicado en la parte superior derecha, tiene sensores representados por las líneas azules.*
- *Los sensores son sonares que miden la **distancia** a los objetos más cercanos.*
- *Los sensores ayudan al robot a determinar una buena distribución a posteriori de a donde se encuentra.*
- *El robot está situado en el medio del pasillo, pero él no lo sabe. Desconoce completamente dónde se encuentra.*



# EJEMPLO 1: PARTICLE FILTER


En este entorno los puntos **rojos** son partículas. Son suposiciones discretas (**hipótesis**) de dónde el robot puede estar. Estas **partículas** están compuestas por las coordenadas  $x$  e  $y$ , y una *orientación*. Estos tres valores determinan una hipótesis. El conjunto de miles de hipótesis es una representación aproximada de la Posterior Belief del robot.





# EJEMPLO 1: PARTICLE FILTER


La esencia del Particle Filter es tener partículas (hipótesis) donde el robot quizás se encuentre. Las partículas pueden “sobrevivir” o no luego de cada iteración del método. Sobreviven las partículas que son más **consistentes** con las mediciones, y más **probables** que sobrevivan. Como resultado lugares con una alta probabilidad concentrarán más partículas, y por lo tanto, mayor representaciones de la Posterior Belief del robot. Todas las partículas juntas conforman la creencia aproximada de la ubicación del robot.



# EJEMPLO 2: PARTICLE FILTER


## EJEMPLO

- Dado un entorno con cuatro *landmarks*. Las distancias desde las *landmarks* al robot conforman el vector medición del robot.
- El robot se encuentra en el medio de las cuatro *landmarks*, y puede medir la distancia a las *landmarks*.
- El ruido de medición es modelado por medio de una Gaussiana con media cero.



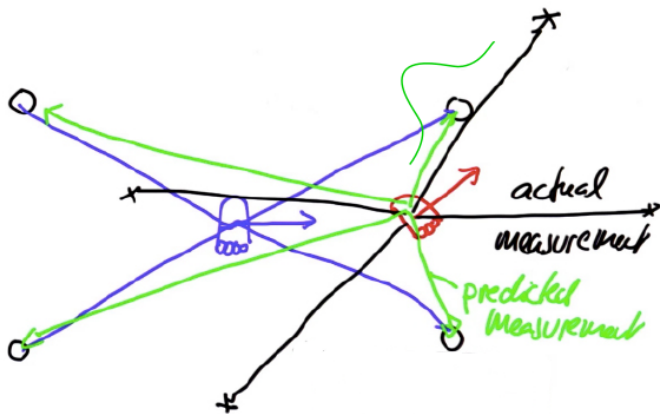
## EJEMPLO 2: PARTICLE FILTER

El robot **rojo** indica la hipótesis de una partícula. Observar que la partícula también presenta una orientación.




## EJEMPLO 2: PARTICLE FILTER

El “mismatch” entre la medición actual (de color **negra**) y la medición predicha (de color **verde**) conduce a lo que llamamos **importance weight**, que dice que tan importante es una partícula específica. Mientras más grande sea este peso, más importante es la partícula.



## EJEMPLO 2: PARTICLE FILTER

Luego del cálculo de los pesos de las partículas, se efectúa un **resampling**. Esto es, cualquier partícula puede sobrevivir, pero la probabilidad de que una partícula sobreviva es proporcional a su peso asociado.



En otras palabras, una partícula con un peso muy grande sobrevivirá con una mayor proporción que una partícula con un peso muy chico.

## RESAMPLING

Dadas  $N$  partículas, donde cada una tiene tres valores y un peso,  $w$ . Los pesos son valores continuos y la suma de todos es  $W$ .

$$W = \sum_i w_i$$

Normalización de los pesos:

La suma de todos los  $\alpha$  es:

$$\alpha_1 = \frac{w_1}{W}$$

$$\alpha_2 = \frac{w_2}{W}$$

$\vdots$

$$\alpha_N = \frac{w_N}{W}$$

$$\sum_i \alpha_i = 1$$

## RESAMPLING (CONTINUACIÓN)

El resampling pone todas las partículas con sus pesos normalizados en un gran “bolsa”. Luego, dibuja las  $N$  nuevas partículas tomando cada partícula con probabilidad  $\alpha$  de la bolsa.

Si hay  $N$  partículas, escogeremos  $N$  veces. Al final, las partículas que posean un mayor peso normalizado  $\alpha$  ocurrirán con mayor frecuencia en el nuevo conjunto.

# EJEMPLO: RESAMPLING

## EJEMPLO (RESAMPLING)

- Dadas las partículas  $p_i$  y sus pesos asociados  $w_i$  donde  $i = 1 \dots 5$ .
- ¿Cuál es la probabilidad de muestrear cada partícula?

$$N=5 \left\{ \begin{array}{ll} p_1 & w_1 = 0.6 \\ p_2 & w_2 = 1.2 \\ p_3 & w_3 = 2.4 \\ p_4 & w_4 = 0.6 \\ p_5 & w_5 = 1.2 \end{array} \right.$$

$$\begin{array}{l} P(p_1) = \boxed{\phantom{0.2}} \\ P(p_2) = \boxed{\phantom{0.2}} \\ P(p_3) = \boxed{\phantom{0.2}} \\ P(p_4) = \boxed{\phantom{0.2}} \\ P(p_5) = \boxed{\phantom{0.2}} \end{array}$$



# EJEMPLO: RESAMPLING

## EJEMPLO (RESAMPLING)

- Dadas las partículas  $p_i$  y sus pesos asociados  $w_i$  donde  $i = 1 \dots 5$ .
- ¿Cuál es la probabilidad de muestrear cada partícula?

N=5	$p_1$	$w_1 = 0.6$	$P(p_1) =$	0.1
	$p_2$	$w_2 = 1.2$	$P(p_2) =$	0.2
	$p_3$	$w_3 = 2.4$	$P(p_3) =$	0.4
	$p_4$	$w_4 = 0.6$	$P(p_4) =$	0.1
	$p_5$	$w_5 = 1.2$	$P(p_5) =$	0.2

$$W = \sum_{i=1}^5 w_i = 6 \quad \rightarrow \quad \alpha_i = \frac{w_i}{W}$$

## EJEMPLO (RESAMPLING)

- Dadas las partículas  $p_i$  y sus pesos asociados  $w_i$  donde  $i = 1 \dots 5$ .
- ¿Es posible que la partícula  $p_1$  nunca sea elegida?

N=5	$p_1$	$w_1 = 0.6$	$\alpha_1 = 0.1$
	$p_2$	$w_2 = 1.2$	$\alpha_2 = 0.2$
	$p_3$	$w_3 = 2.4$	$\alpha_3 = 0.4$
	$p_4$	$w_4 = 0.6$	$\alpha_4 = 0.1$
	$p_5$	$w_5 = 1.2$	$\alpha_5 = 0.2$

Si

No

# EJEMPLO: RESAMPLING

## EJEMPLO (RESAMPLING)

- Dadas las partículas  $p_i$  y sus pesos asociados  $w_i$  donde  $i = 1 \dots 5$ .
- ¿Es posible que la partícula  $p_1$  nunca sea elegida?

N=5	$p_1$	$w_1 = 0.6$	$\alpha_1 = 0.1$
	$p_2$	$w_2 = 1.2$	$\alpha_2 = 0.2$
	$p_3$	$w_3 = 2.4$	$\alpha_3 = 0.4$
	$p_4$	$w_4 = 0.6$	$\alpha_4 = 0.1$
	$p_5$	$w_5 = 1.2$	$\alpha_5 = 0.2$

Si No

Es muy probable que  $p_1$  nunca sea elegida ya que tiene un peso muy chico.

# EJEMPLO: RESAMPLING

## EJEMPLO (RESAMPLING)

- Dadas las partículas  $p_i$  y sus pesos asociados  $w_i$  donde  $i = 1 \dots 5$ .
- ¿Es posible que la partícula  $p_3$  nunca sea elegida?

N=5	$p_1$	$w_1 = 0.6$	$\alpha_1 = 0.1$
	$p_2$	$w_2 = 1.2$	$\alpha_2 = 0.2$
	$p_3$	$w_3 = 2.4$	$\alpha_3 = 0.4$
	$p_4$	$w_4 = 0.6$	$\alpha_4 = 0.1$
	$p_5$	$w_5 = 1.2$	$\alpha_5 = 0.2$

Si

No

## EJEMPLO (RESAMPLING)

- Dadas las partículas  $p_i$  y sus pesos asociados  $w_i$  donde  $i = 1 \dots 5$ .
- ¿Es posible que la partícula  $p_3$  nunca sea elegida?

N=5	$p_1$	$w_1 = 0.6$	$\alpha_1 = 0.1$
	$p_2$	$w_2 = 1.2$	$\alpha_2 = 0.2$
	$p_3$	$w_3 = 2.4$	$\alpha_3 = 0.4$
	$p_4$	$w_4 = 0.6$	$\alpha_4 = 0.1$
	$p_5$	$w_5 = 1.2$	$\alpha_5 = 0.2$

Si            No  
Si bien es poco probable, es posible que  $p_3$  nunca sea elegida.

# EJEMPLO: RESAMPLING

## EJEMPLO (RESAMPLING)

- Dadas las partículas  $p_i$  y sus pesos asociados  $w_i$  donde  $i = 1 \dots 5$ .
- ¿Cuál es la probabilidad de que la partícula  $p_3$  nunca sea elegida?

N=5	$p_1$	$w_1 = 0.6$	$\alpha_1 = 0.1$
	$p_2$	$w_2 = 1.2$	$\alpha_2 = 0.2$
	$p_3$	$w_3 = 2.4$	$\alpha_3 = 0.4$
	$p_4$	$w_4 = 0.6$	$\alpha_4 = 0.1$
	$p_5$	$w_5 = 1.2$	$\alpha_5 = 0.2$

$P(p_3 \text{ no sea muestreada}) = ?$

# EJEMPLO: RESAMPLING

## EJEMPLO (RESAMPLING)

- Dadas las partículas  $p_i$  y sus pesos asociados  $w_i$  donde  $i = 1 \dots 5$ .
- ¿Cuál es la probabilidad de que la partícula  $p_3$  nunca sea elegida?

N=5	$p_1$	$w_1 = 0.6$	$\alpha_1 = 0.1$
	$p_2$	$w_2 = 1.2$	$\alpha_2 = 0.2$
	$p_3$	$w_3 = 2.4$	$\alpha_3 = 0.4$
	$p_4$	$w_4 = 0.6$	$\alpha_4 = 0.1$
	$p_5$	$w_5 = 1.2$	$\alpha_5 = 0.2$

$$P(p_3 \text{ no sea muestreada}) = (0,6)^5 = 0,077$$

## DEFINICIÓN (MEASUREMENT UPTADE)

$$P(X|z) \propto P(z|X)P(X)$$

$P(X)$  : conjunto de partículas

$P(z|X)$  : importance weight

$P(X|z)$  : Posterior Belief luego de haber sentido

## DEFINICIÓN (MOTION UPTADE)

$$P(X') = \sum P(X'|X)P(X)$$

$P(X)$  : conjunto de partículas

$P(X'|X)$  : motion model con noise model

$P(X')$  : nuevo conjunto de partículas (Posterior Belief luego del movimiento)



---

**Algorithm 1:** Particle Filter( $\mathcal{X}_{t-1}, u_t, z_t$ )

---

$\bar{\mathcal{X}}_t = \mathcal{X}_t = \emptyset$

for  $m = 1$  to  $M$  do

*sample*  $x_t^{[m]} \sim p(x_t | u_t, x_{t-1}^{[m]})$

$w_t^m = p(z_t | x_t^{[m]})$

$\bar{\mathcal{X}}_t = \bar{\mathcal{X}}_t + \langle x_t^{[m]}, w_t^{[m]} \rangle$

endfor

for  $i = 1$  to  $M$  do

    draw  $i$  with probability  $\propto w_t^{[i]}$

    add  $x_t^{[i]}$  to  $\mathcal{X}_t$

endfor

return  $\mathcal{X}_t$

---