

# **Aprendizaje reforzado: Conceptos básicos y aplicaciones en robótica**

Dr.-Ing. Miguel A. Solis

**XIII IEEE Escuela de Verano  
Latino-Americana en Inteligencia Computacional**

13 Diciembre de 2017

*Material disponible en  
[innovacionyrobotica.com/~miguel.solis](http://innovacionyrobotica.com/~miguel.solis)*

# Estructura del Tutorial

## Introducción

## Aprendizaje reforzado

Fundamentos

Definición de un problema en RL

## Métodos

Value Iteration

Policy Iteration

Q-learning

## Aplicaciones en robótica



# Introducción

## Aprendizaje reforzado

Fundamentos

Definición de un problema en RL

## Métodos

Value Iteration

Policy Iteration

Q-learning

## Aplicaciones en robótica



# Tipos de aprendizaje

- ▶ Aprendizaje Supervisado: encontrar un mapeo de entrada a salida, supervisor provee valores correctos.
- ▶ Aplicaciones:
  - ▶ Reconocimiento de rostros, escritura, gestos
  - ▶ Diagnóstico médico
  - ▶ ...



# Detección de Spam

The screenshot shows an email interface with the following details:

- Subject:** SCORE HUGE SAVINGS on the BEST DRUGS.
- To:** Tressa Gruger <bklykywo@sk.ca>
- Date:** 30 de Jul. (hace 4 días)
- Language:** griego (selected) > español > Traducir mensaje
- Spam Alert:** A yellow bar at the top right says, "¿Por qué este mensaje se encuentra en la carpeta Spam? Está escrito en un idioma distinto al que se utiliza normalmente en tus mensajes. [Más información](#)".
- Content:** The email body contains large red text: "HIGH-QUALITY MEDICATIONS FOR THE BEST PRICE!" followed by a blue link "CLICK HERE...". Below this, under "MEN'S HEALTH:", it lists prices for various medications: "Viagra as low as \$0.99", "Viagra Super Active+ as low as \$2.55", "Viagra Super Force as low as \$4.25", "Cialis as low as \$1.59", "Viagra Professional as low as \$3.50", and "Cialis Super Active+ as low as \$2.99". At the bottom, it says "ANTI-ALLERGIC/ASTHMA:" followed by two large red rectangular boxes.

- ▶ Entrada: palabras en correo, junto con la cantidad de repeticiones
- ▶ Salida: Spam / No-Spam

# Detección de rostros

- ▶ Datos de entrenamiento (rostros y no-rostros)



- ▶ Datos de validación



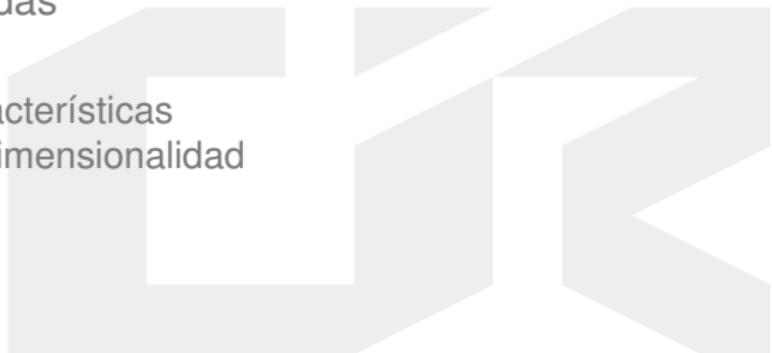
# Reconocimiento de objetos

Italian Institute of Technology



# Tipos de aprendizaje

- ▶ Aprendizaje no supervisado: de los datos de entrenamiento, sólo se conocen las entradas
- ▶ Aplicaciones:
  - ▶ Extracción de características
  - ▶ Reducción de la dimensionalidad



# Reconocimiento de esqueletos

University of Toronto



# Aprendizaje reforzado

- ▶ Aprende de interacciones con el entorno
- ▶ Aplicaciones:
  - ▶ Problemas de decisión secuencial
  - ▶ Sistemas adaptivos



# Introducción

## Aprendizaje reforzado

Fundamentos

Definición de un problema en RL

## Métodos

Value Iteration

Policy Iteration

Q-learning

## Aplicaciones en robótica



# Psicología

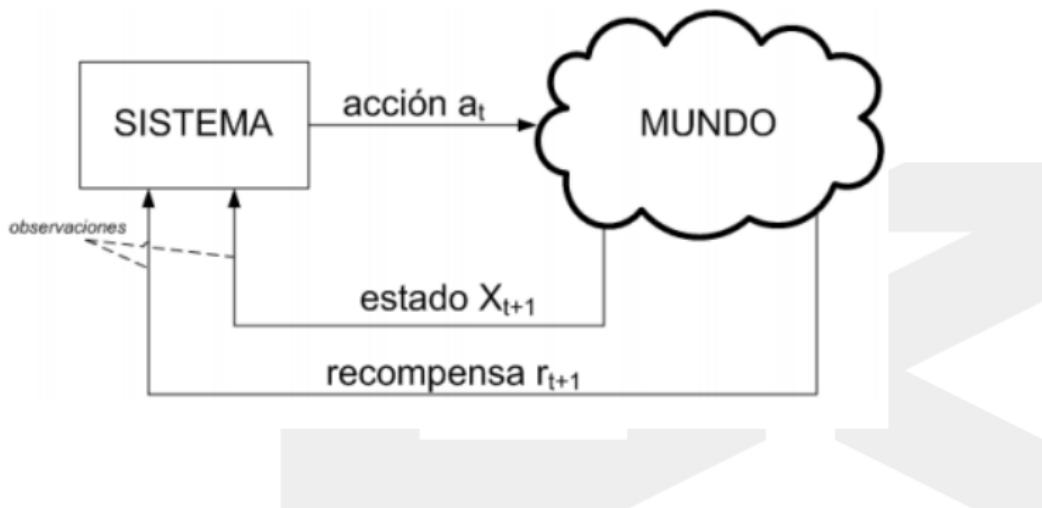
- ▶ Edward L. Thorndike - Animal Intelligence: An experimental study of the associate processes in animals (1898)
- ▶ El animal modifica su conducta según interacción de prueba y error con el medio ambiente

# Interacción

El **agente** interactúa con el entorno a través de percepciones y acciones.

- ▶ Recibe como entrada (percibe), el estado actual del entorno,  $s$ .
- ▶ Luego, genera una acción (ejecuta)  $a$  como salida.
- ▶ Recibe una señal de refuerzo (recompensa).

# Esquema



# Elementos

Un problema de aprendizaje reforzado (RL - Reinforcement Learning), formulado como un MDP (Proceso de Decisión Markoviano) está compuesto por ( $S, A, T, R$ ) donde...

- ▶ ¿Markoviano?



# Proceso de Markov

Un estado  $s_k$  se dice que obedece a un proceso de Markov (de 1er orden) ssi:

$$Pr\{s_{k+1}|s_k\} = Pr\{s_{k+1}|s_1, \dots, s_k\},$$

# Elementos

Un problema de aprendizaje reforzado, formulado como un MDP (Proceso de Decisión Markoviano) está compuesto por  $(S, A, T, R)$  donde

- ▶  $S$ : Conjunto de estados
- ▶  $A$ : Conjunto de acciones
- ▶  $T: S \times A \times S \rightarrow [0, 1]$  (**desconocido**)
- ▶  $R: S \times A \times S \rightarrow \mathbb{R}$ .
- ▶  $\pi: S \rightarrow A$ .



# Aprendizaje Reforzado

Estado  $s_k \in S$  : Acción  $a_k \in A$

$$s_k \xrightarrow{a_k} s_{k+1}$$

Función de transición de estado  $T$ :

$$s_{k+1} = T(s_k, a_k)$$

# Recompensas

$$r_k = r(s_{k-1}, a_k, s_k)$$

- ▶  $r_k > 0$
- ▶  $r_k = 0$
- ▶  $r_k < 0$

Política  $\pi: S \rightarrow A$

Una política es óptima si maximiza la recompensa a largo plazo

# Retorno

Función de Valor:

$$V^\pi(s_k) = r_k + \gamma r_{k+1} + \gamma^2 r_{k+2} + \dots = \sum_{i=0}^{\infty} \gamma^i r_{k+i}$$

$$0 \leq \gamma < 1, \quad r_k \text{ acotado}$$

Una política  $\pi^*$  es óptima si:

$$V^*(s) = V^{\pi^*}(s) \geq V^\pi(s) \quad \forall s, \pi$$

# Introducción

## Aprendizaje reforzado

Fundamentos

Definición de un problema en RL

## Métodos

Value Iteration

Policy Iteration

Q-learning

## Aplicaciones en robótica



# Value Iteration

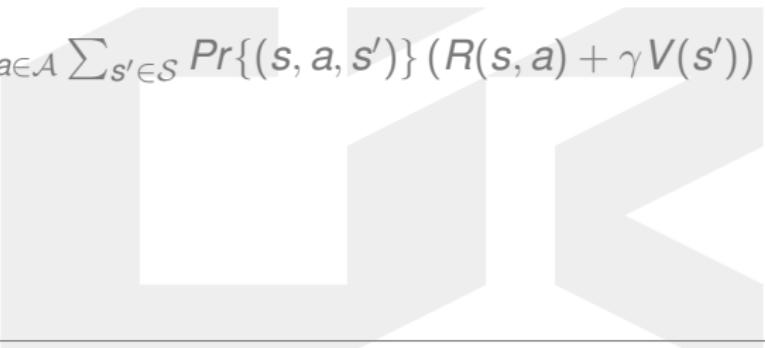
Consiste en realizar  $k$  iteraciones, hasta que  $V_k(s) - V_{k-1}(s)$  es suficientemente pequeño, con actualización según

$$V_k(s) = \max_a \sum_{s'} p(s', s, a) \cdot (r(s', s, a) + \gamma V_{k-1}(s'))$$

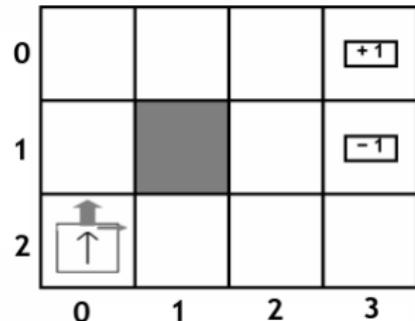
# Value Iteration

---

```
1:  $k = 0$ 
2:  $\hat{V}_0(x) = 0 \quad \forall s \in \mathcal{S}$ 
3: while  $\Delta > \epsilon$  do ▷ (para  $\epsilon$  pequeño)
4:   for  $s \in \mathcal{S}$  do
5:      $\hat{V}_{k+1}(x) = \max_{a \in \mathcal{A}} \sum_{s' \in \mathcal{S}} Pr\{(s, a, s')\} (R(s, a) + \gamma V(s'))$ 
6:   end for
7:    $\Delta = \|\hat{V}_{k+1} - \hat{V}_k\|$ 
8:    $k = k + 1$ 
9: end while
10: return  $\pi$ 
```



# Ejemplo 1 (ver Python Notebook)



- ▶ Estados: ubicación en la grilla
- ▶ Acciones: arriba, izquierda, derecha, abajo
- ▶ Recompensa: +1, -1, -0.1

# Ejemplo 1 (ver Python Notebook)

Después de 1 iteración:

0	-0.1	-0.1	1	+1
1	-0.19		-0.1	-1
2	-0.1	-0.1	-0.19	-0.1

# Ejemplo 1 (ver Python Notebook)

Después de 2 iteraciones:

0	0.62	0.8	1	+1
1	0.46		0.8	-1
2	-0.27	-0.19	0.62	-0.27

# Ejemplo 1 (ver Python Notebook)

En convergencia:

0	0.62	0.8	1	+1
1	0.46		0.8	-1
2	0.31	0.46	0.62	0.46

# Toma de decisiones

Entonces...

$$V_k(s) = \max_a \sum_{s'} p(s', s, a) \cdot (r(s', s, a) + \gamma V_{k-1}(s'))$$

- ▶ debo ejecutar necesariamente la acción que maximiza este argumento?
  - ▶ comportamiento greedy
  - ▶ comportamiento  $\epsilon$ -greedy

# Policy Iteration

- 
- 1:  $\hat{\pi}_0(s) = \text{acción aleatoria}$
  - 2:  $\hat{V}_0(s) = 0 \quad \forall s \in \mathcal{S}$
  - 3: evaluar\_politica()
  - 4: mejorar\_politica()
- 

$\forall s \in \mathcal{S}$

▷ arbitrariamente



# Policy Iteration

evaluar\_politica():

---

```
1:  $k = 0$ 
2: while  $\Delta > \epsilon$  do ▷ (para  $\epsilon$  pequeño)
3:   for  $s \in \mathcal{S}$  do
4:      $\hat{V}_{k+1}(s) = \max_{a \in \mathcal{A}} \sum_{s' \in \mathcal{S}} Pr\{(s, a, s')\} (R(s, a) + \gamma V(s'))$ 
5:   end for
6:    $\Delta = \|\hat{V}_{k+1} - \hat{V}_k\|$ 
7:    $k = k + 1$ 
8: end while
```

---

# Policy Iteration

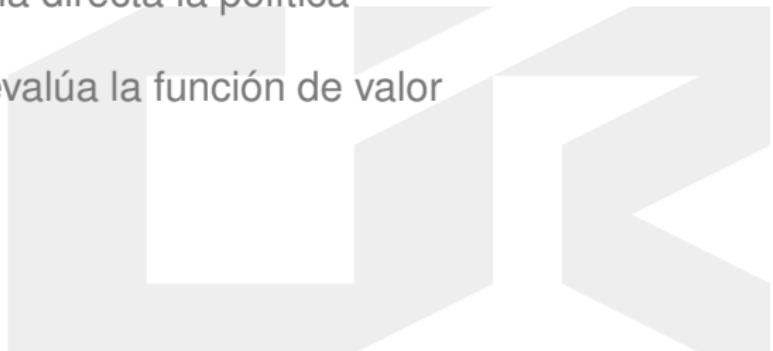
mejorar\_politica() :

---

```
1: politica_estable = true
2: k = 0
3: for s ∈  $\mathcal{S}$  do
4:      $\hat{\pi}_{k+1}(s) = \operatorname{argmax}_{a \in \mathcal{A}} \sum_{s' \in \mathcal{S}} \Pr\{(s, a, s')\} (R(s, a) + \gamma V(s'))$ 
5:     if  $\hat{\pi}_k(s) \neq \hat{\pi}_{k+1}(s)$  then
6:         politica_estable = false
7:     end if
8: end for
9: if politica_estable then
10:    return  $\hat{\pi}_k$ 
11: else
12:    evaluar_politica()
13: end if
```

## Ejemplo 2 (ver Python Notebook)

- ▶ Se encuentra de forma directa la política
- ▶ De todas formas se evalúa la función de valor



# Valor $Q$

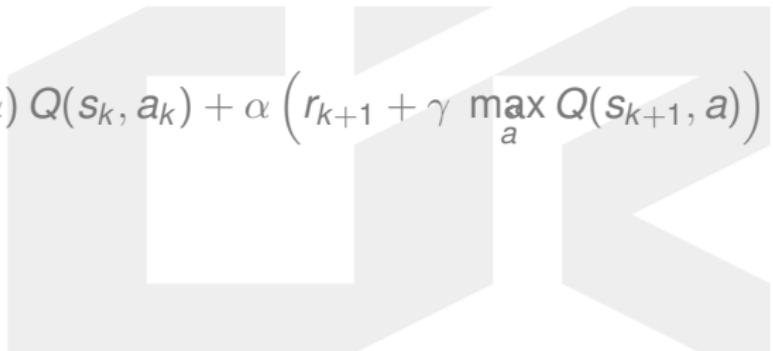
- ▶ Así como  $V(s)$  corresponde a la función que valoriza el estado,  $Q(s, a)$  corresponde a la función que valoriza el tomar cierta acción en ese estado.
- ▶ Para una política óptima  $\pi^*$ , se cumple

$$Q^*(s, a) \geq Q^\pi(s, a) \quad \forall s, a, \pi$$

# Q-learning

- ▶ Consiste en iterar sobre cada par (estado,acción), para  $\alpha$  y  $\gamma$  fijos.
- ▶ Actualización:

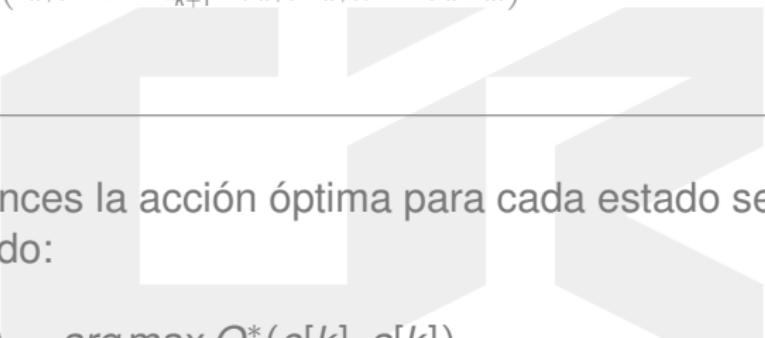
$$Q(s_k, a_k) \leftarrow (1 - \alpha) Q(s_k, a_k) + \alpha \left( r_{k+1} + \gamma \max_a Q(s_{k+1}, a) \right)$$



# Q-learning

---

```
1:  $\hat{Q}(s_0, a_0) = 0 \quad \forall s \in \mathcal{S}, \quad a \in \mathcal{A}$ 
2: for  $k = 1, 2, \dots, n$  do
3:   Observar  $s_k, a_k, R(s_k, a_k), s_{k+1}$ 
4:    $\hat{Q}(s_k, a_k) = \hat{Q}(s_k, a_k) + \alpha \left( R_{k+1} + \gamma \max_{a_{k+1}} \hat{Q}(s_{k+1}, a_{k+1}) - \hat{Q}(s_k, a_k) \right)$ 
5: end for
6: return  $\hat{Q}$ 
```

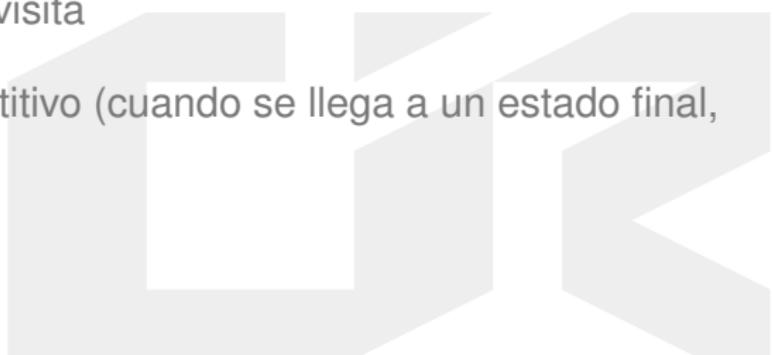


Suponiendo  $\hat{Q} = Q^*$ , entonces la acción óptima para cada estado se puede obtener maximizando:

$$\pi^*(s[k]) = \arg \max_{a[k]} Q^*(s[k], a[k]),$$

# Ejemplo 3 (ver Python Notebook)

- ▶ No se realizan iteraciones sobre todo el espacio de estados, sólo cuando el estado se visita
- ▶ Este ejemplo es repetitivo (cuando se llega a un estado final, vuelve al inicio)



# Introducción

## Aprendizaje reforzado

Fundamentos

Definición de un problema en RL

## Métodos

Value Iteration

Policy Iteration

Q-learning

## Aplicaciones en robótica

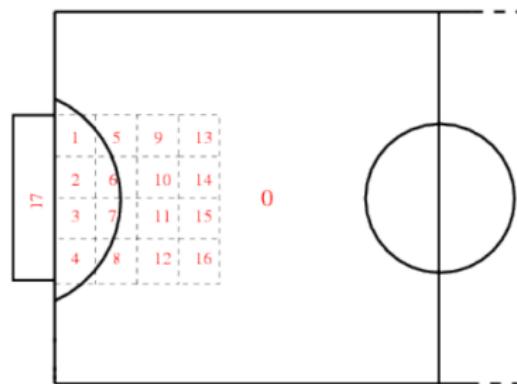


# RoboCup SSL

- ▶ G.A. Ahumada, C.J. Nettle and M.A. Solis, 'Accelerating Q-learning through Kalman Filter Estimations applied in a RoboCup SSL Simulation', **Proceedings** of the 10th IEEE Latin American Robotics Symposium, 2013.



# RoboCup SSL

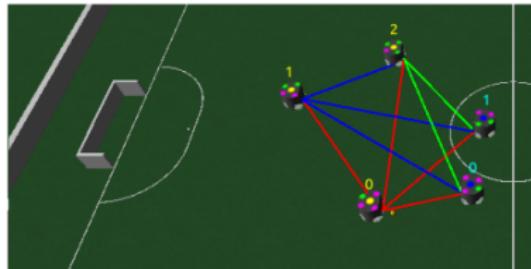


Estado compuesto por

- ▶ posición de pelota
- ▶ posición y orientación de arquero

# RoboCup SSL

Generación de estrategia defensiva



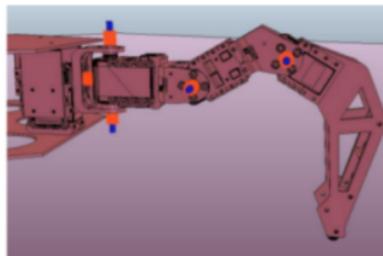
estado compuesto por:

- ▶  $\text{dist}(K_i, \text{pelota}), \text{dist}(T_j, \text{pelota})$
- ▶  $\text{dist}(K_i, K_j)$
- ▶  $\text{dist}(K_i, T_j)$
- ▶  $\text{angle}(K_i, T_j)$

Memoria de Ingeniería Civil Informática - Franco Ollino (2016)

# Generación de caminata

- ▶ O. Silva and M.A. Solis, 'Evolutionary Function Approximation for Gait Generation on Legged Robots'. **Book Chapter:** Nature-Inspired Computing for Control Systems, Springer, 2016.



# Generación de caminata

El estado viene dado por la posición de cada uno de los 18 motores

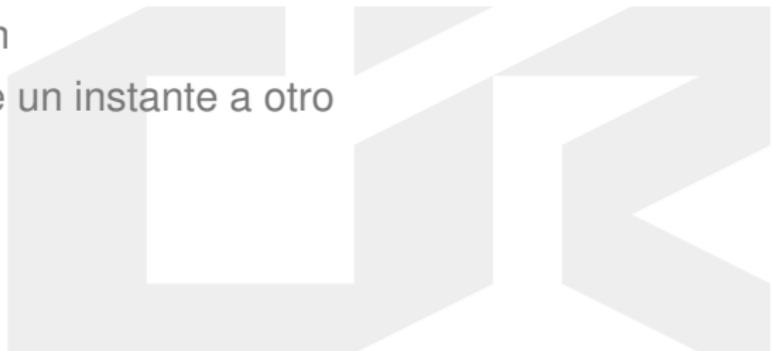
$$s = (m_1, m_2, \dots, m_{18}),$$

donde  $m_i$  corresponde al  $i$ -ésimo motor, notando que algunos están limitados a  $[-45, 45]$  grados, y  $[-90, 90]$  grados.

# Generación de caminata

La recompensa es

- ▶ -1 en caso de colisión
- ▶ distancia recorrida de un instante a otro

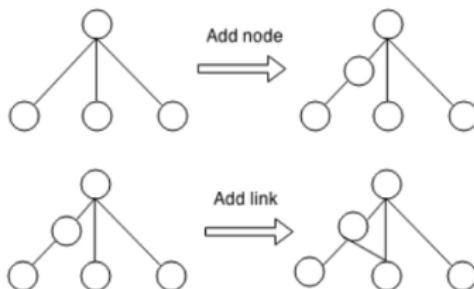


# Generación de caminata

representación de estados

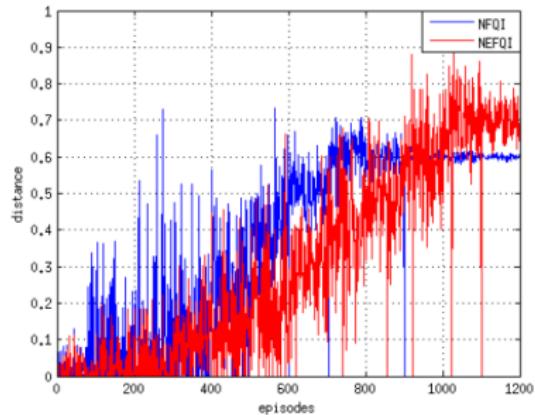
- No tabular
- NEAT+Q

NEAT:



# Generación de caminata

evaluación de desempeño



# Lectura recomendada

- ▶ Richard S. Sutton and Andrew G. Barto. **Reinforcement Learning: An Introduction**, 1998.
- ▶ Jens Kober, J Andrew Bagnell, and Jan Peters. **Reinforcement learning in robotics: A survey**. The International Journal of Robotics Research, 32(11):1238–1274, 2013

# Preguntas?

