

An abstract graphic featuring a dark green sphere at the top center, positioned above two overlapping, tilted geometric shapes. The shape on the left is a dark, almost black, parallelogram, while the one on the right is a lighter green parallelogram. The background is a solid, dark green color.

Aprendizaje por Refuerzo

Basado en Modelos



Borja

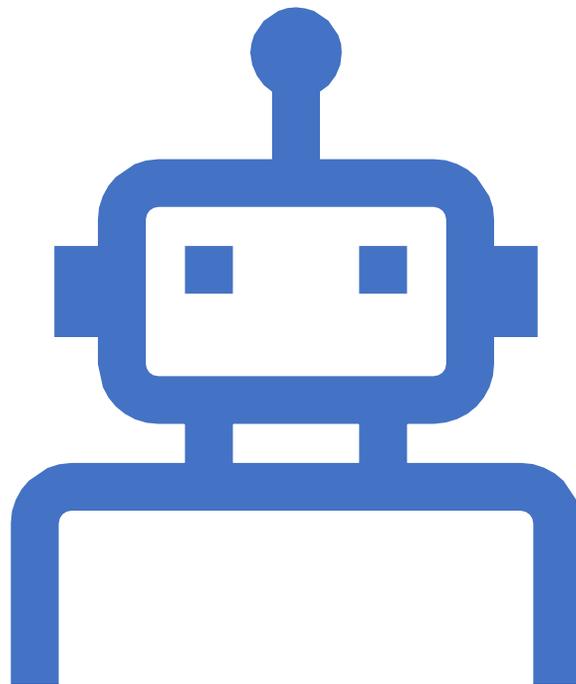


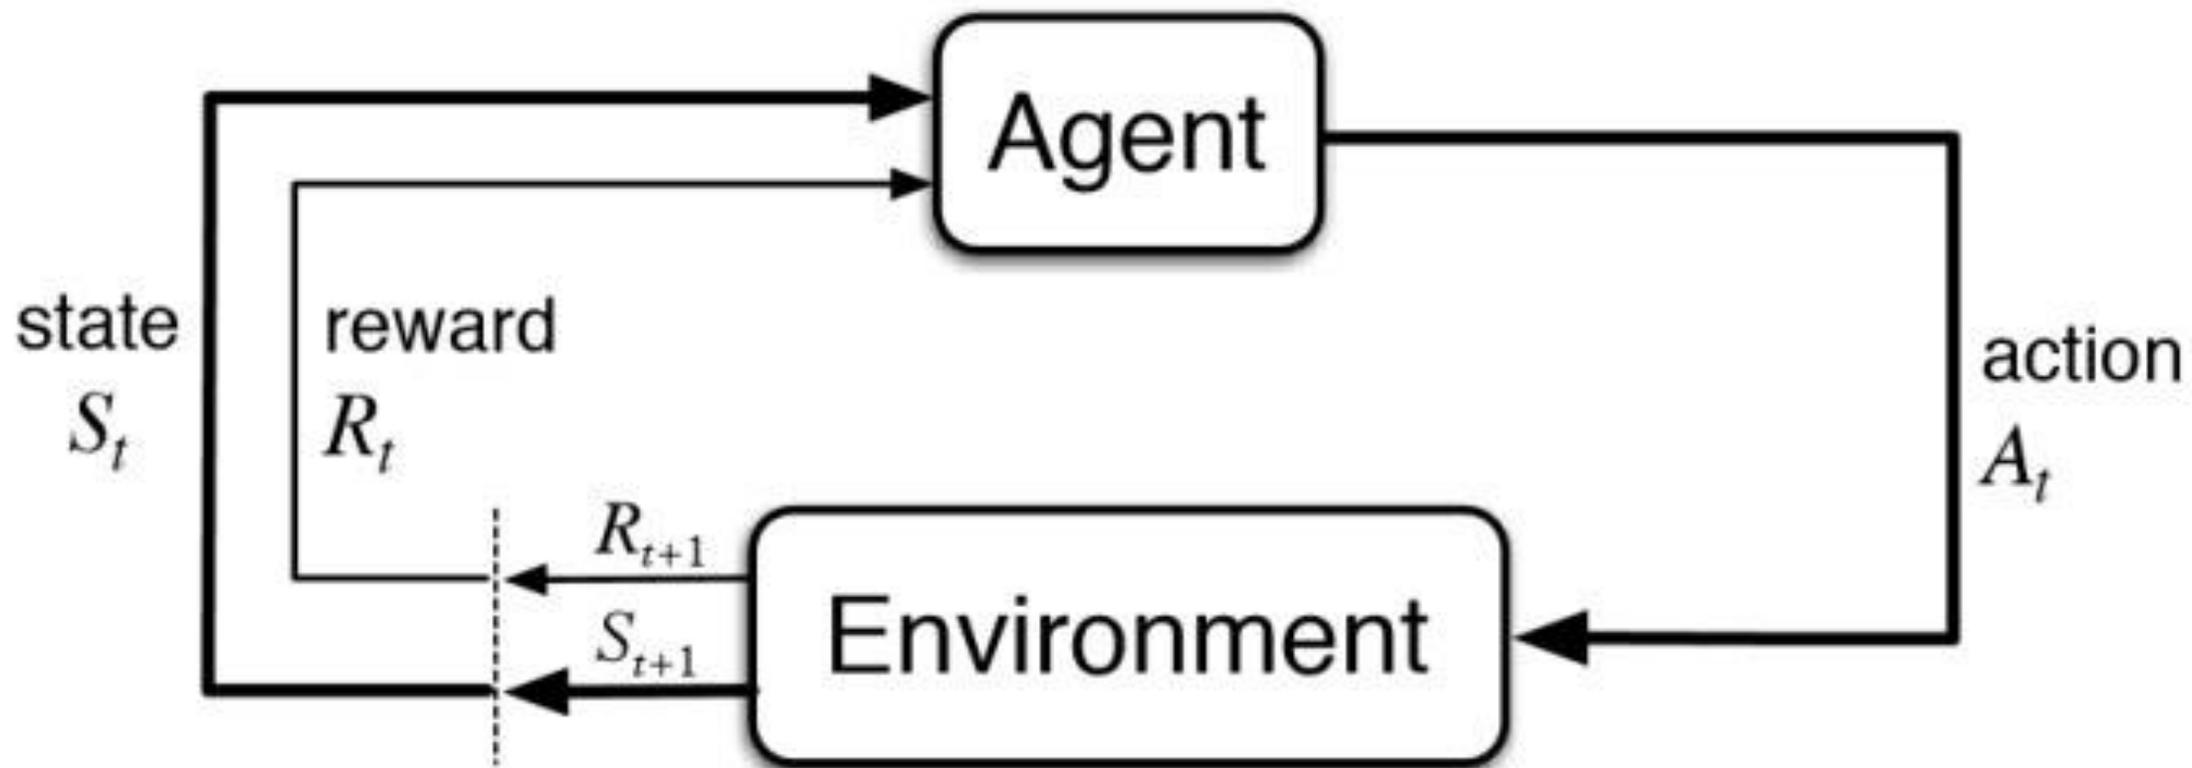
Imperial College
London

Sobre mi

- Investigador Doctoral en el **Imperial College de Londres**
- Mi trabajo se centra en mejorar las capacidades de generalización del **aprendizaje por refuerzo profundo** mediante el uso de **IA simbólica**. Con especial atención a las aplicaciones en **sistemas multi-agente**.

¿Qué es el Aprendizaje por Refuerzo?

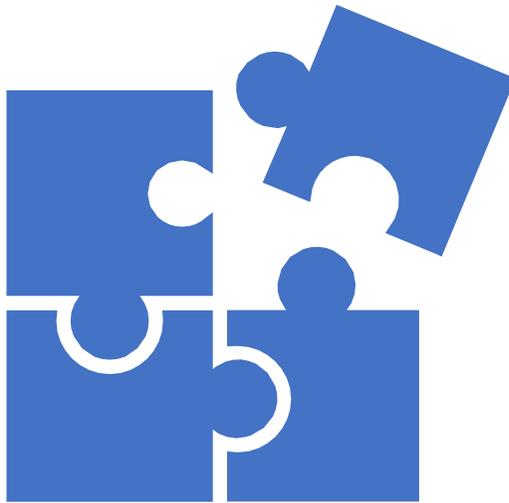




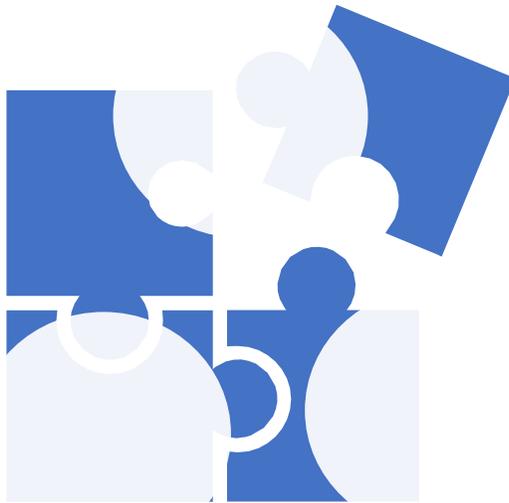
Modelo de Decision de Markov (MDP)

Un Modelo de Decision de Markov es una tupla $\langle S, A, P_{s,a}, \gamma, R \rangle$ donde:

- S es un conjunto de estados.
- $A = \{a_1, a_2, \dots, a_k\}$ es un conjunto de acciones.
- $P_{s,a}(\cdot)$ son las probabilidades de transición desde un estado s tomando la acción a .
- $\gamma \in [0,1)$ es el factor de descuento.
- $R: S \rightarrow \mathbb{R}$ es la función de recompensas



MDP Parcialmente Observable (POMDP)



Un Modelo de Decision de Markov parcialmente observable es una tupla $\langle S, A, P_{s,a}, O, Z, \gamma, R \rangle$ donde:

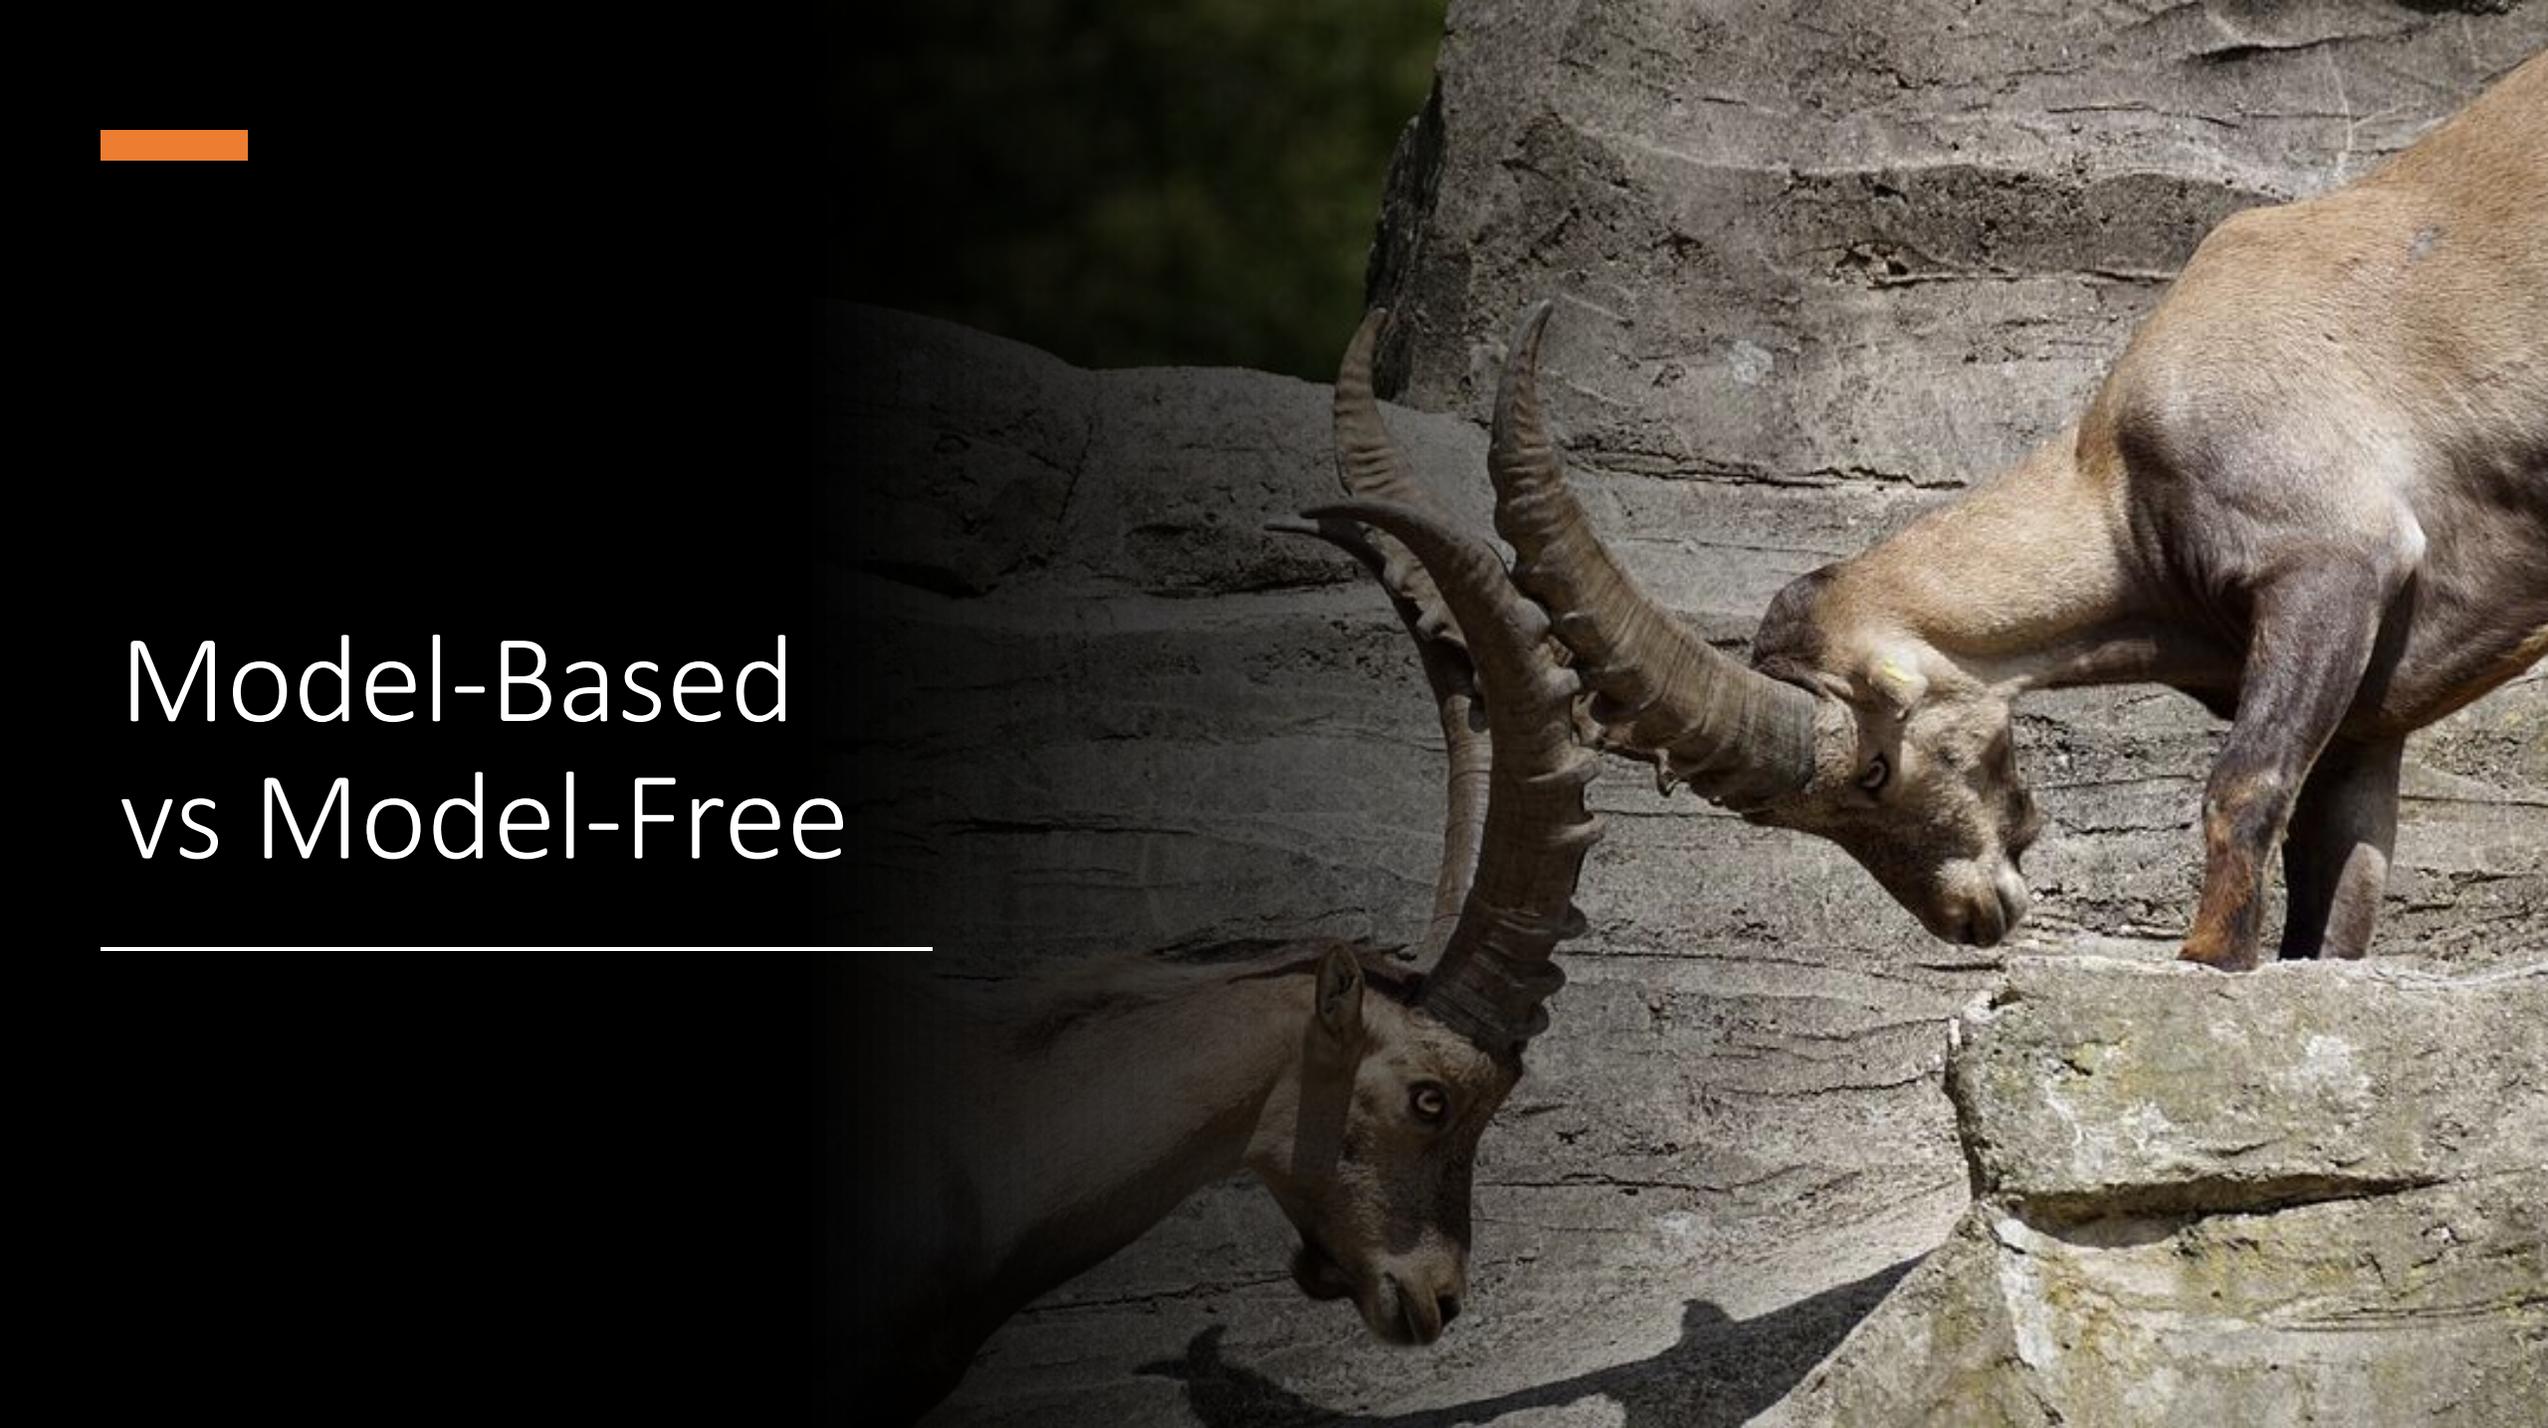
- S, A, P, γ y R son iguales que en el modelo anterior
- Z es el conjunto de posibles observaciones.
- $O(s,a): S \times A \rightarrow Z$ es la función de observación

Ecuaciones de Bellman y Optimalidad

$$V^\pi(s) = R(s) + \gamma \sum_{s'} P_{s\pi(s)}(s') V^\pi(s')$$

$$Q^\pi(s, a) = R(s) + \gamma \sum_{s'} P_{sa}(s') V^\pi(s')$$

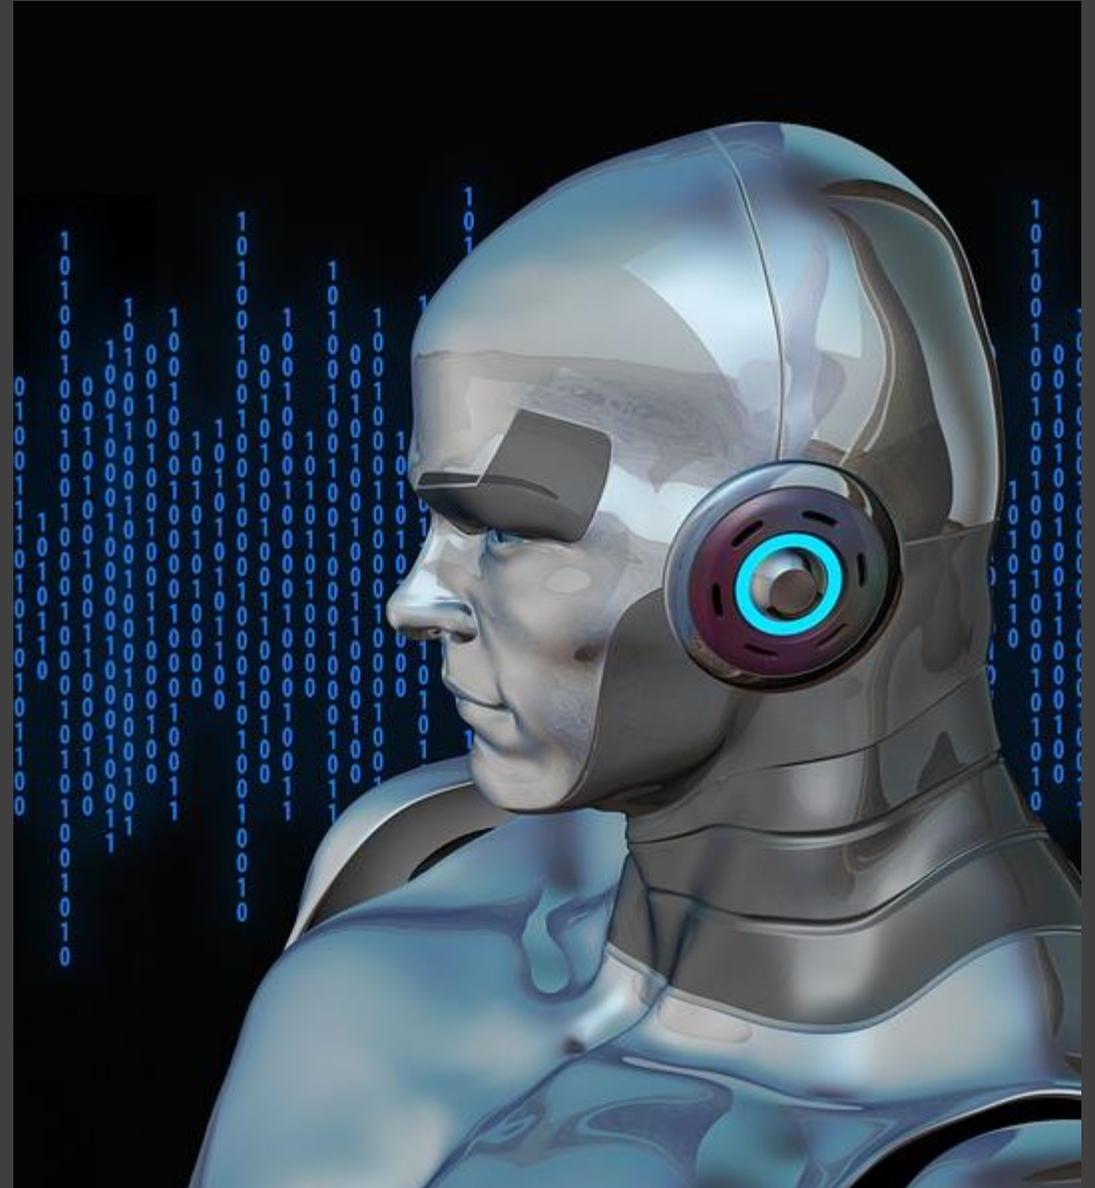
$$\pi^*(s) \in \arg \max_{a \in A} Q^\pi(s, a)$$



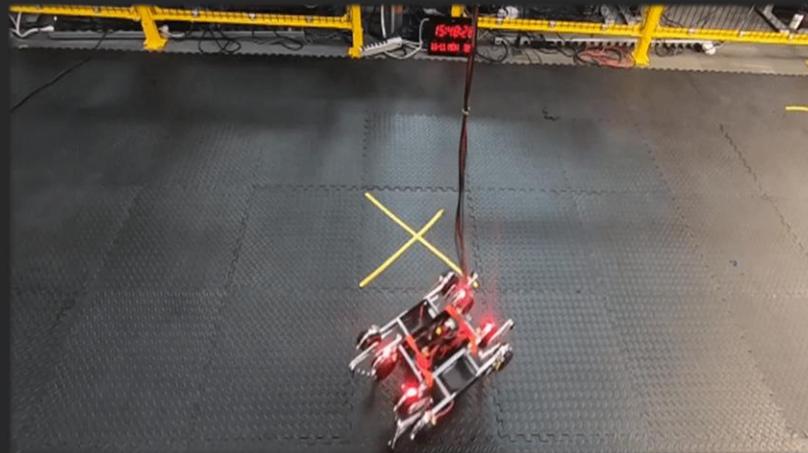
Model-Based
vs Model-Free

¿Debemos pensar antes de actuar?

- Un agente sin modelo (Model-free) puede ser visto como uno que actúa por intuición
- Un agente que usa modelos (Model-based) “imagina” las posibilidades que puede explotar con sus acciones antes de actuar

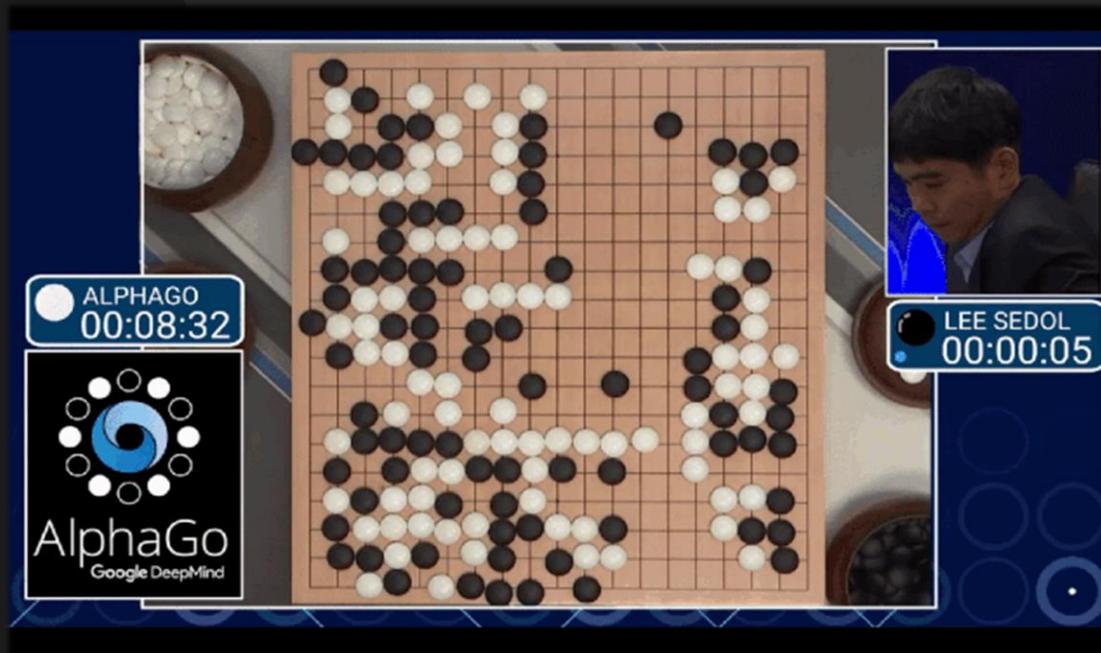


Casos de éxito de Model-free RL

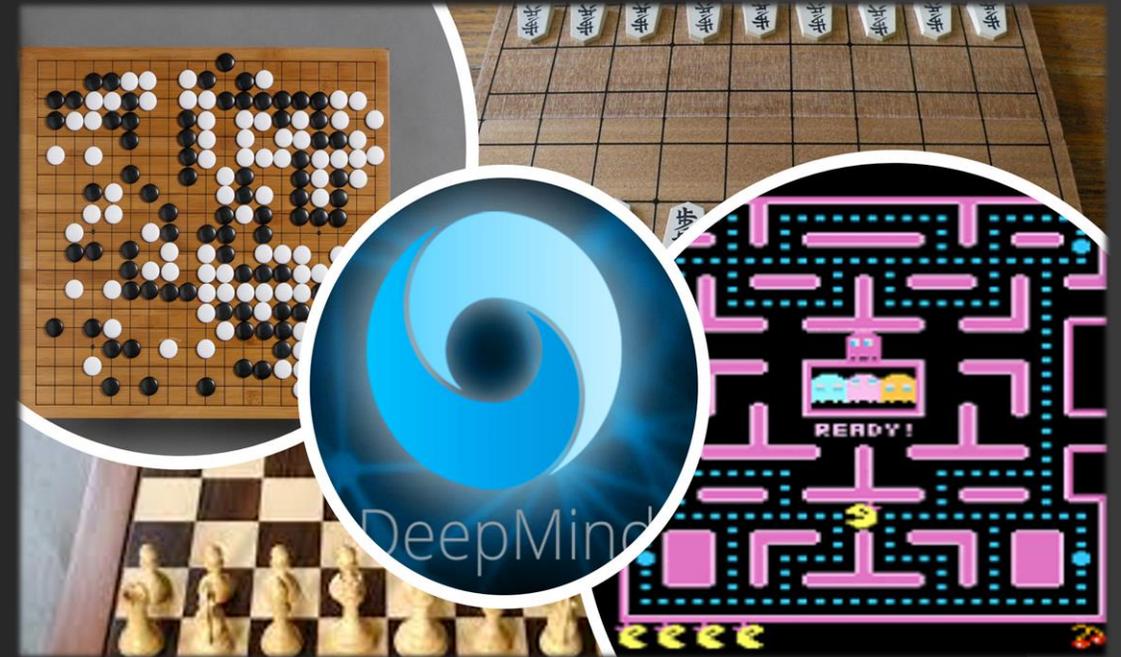


Casos de éxito de Model-Based RL

AlphaGo & AlphaZero



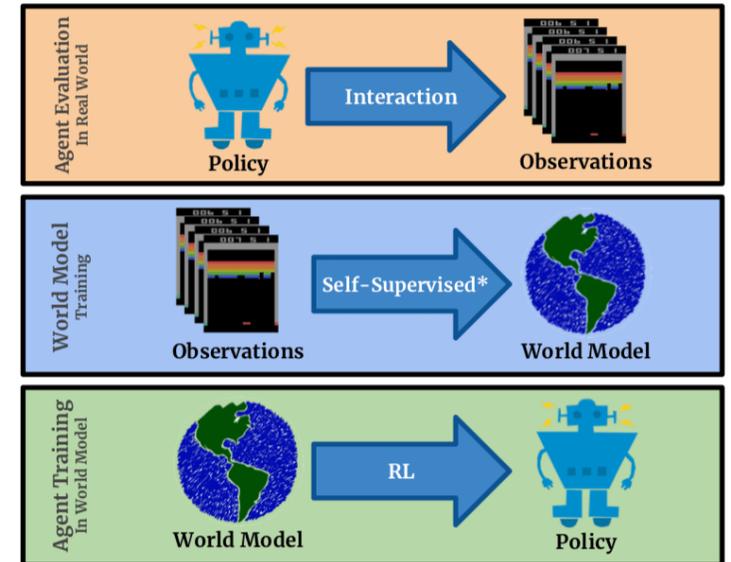
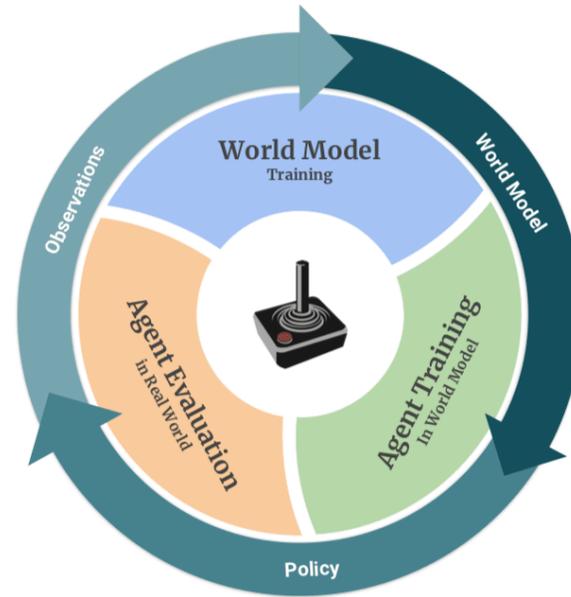
MuZero



Aprendizaje por Refuerzo

Basado en Modelos

Model-Based Reinforcement Learning for Atari

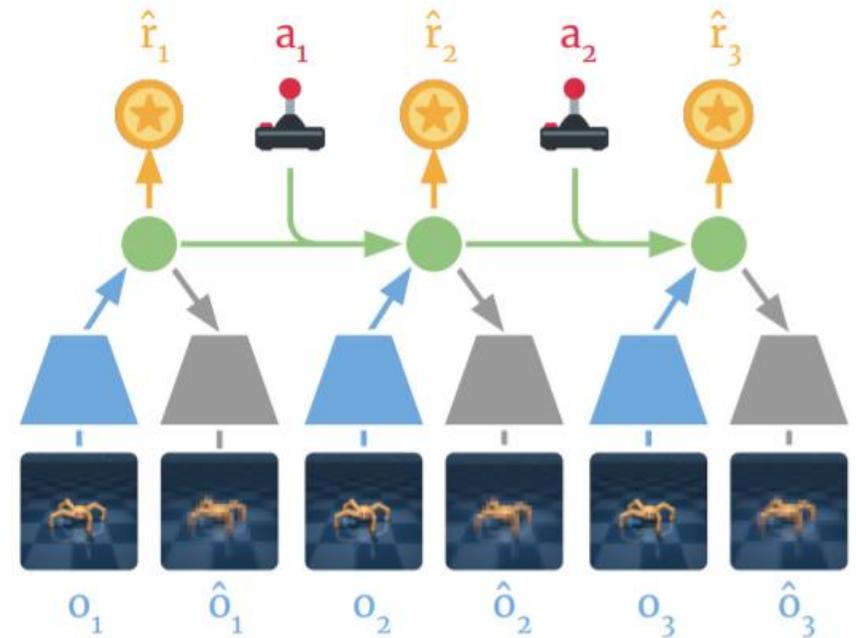


¿Cómo va esto?

- Muy similar al aprendizaje por refuerzo que no usa modelos: MDP, ecuaciones de Bellman...
- La mayor diferencia está en la construcción y utilización de un modelo para “imaginar” o simular lo que puede pasar.
- Una vez construido, si el modelo es bueno, podemos usar algoritmos de aprendizaje por refuerzo o de planificación
- Reduce enormemente el número de iteraciones necesarias con el entorno real.

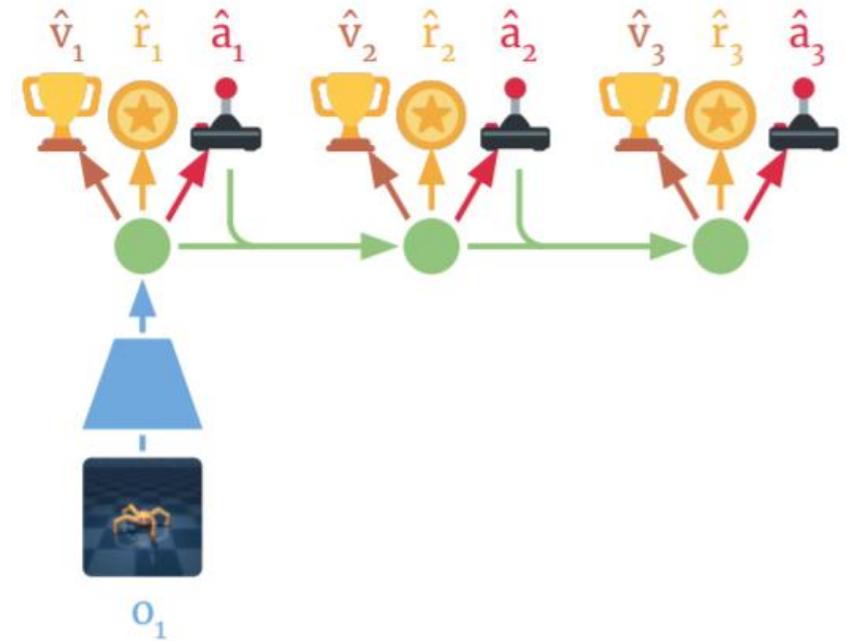
Iteraciones típicas

- Aprender las dinámicas del mundo en el que nos movemos



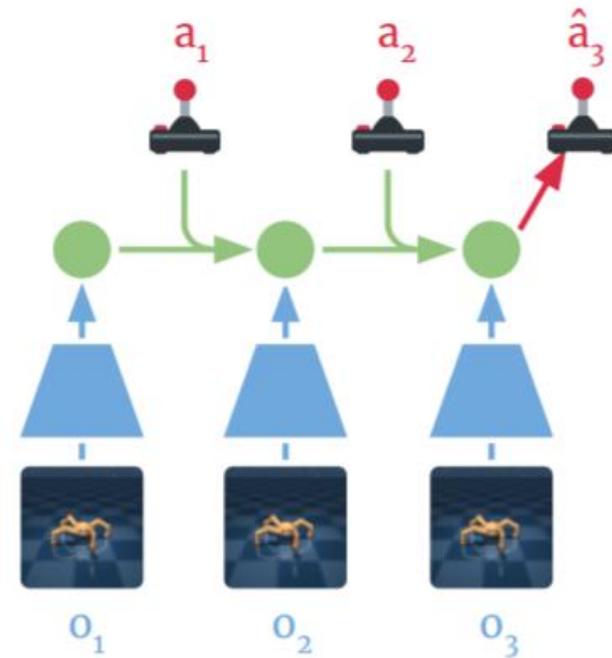
Iteraciones típicas

- Aprender las dinámicas del mundo en el que nos movemos
- Aprender a predecir las recompensas que se pueden obtener y las secuencias de estados y acciones que llevan a ellas

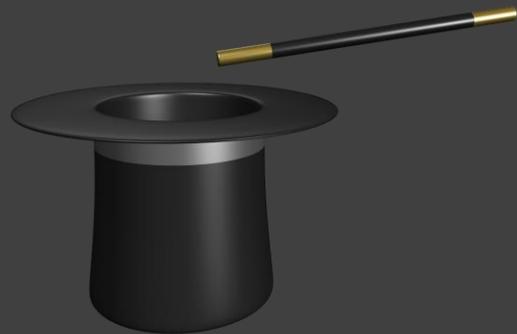


Iteraciones típicas

- Aprender las dinámicas del mundo en el que nos movemos
- Aprender a predecir las recompensas que se pueden obtener y las secuencias de estados y acciones que llevan a ellas
- Actuar en el entorno real



¿Dónde está el truco?



AQUÍ GRAN PARTE DEL TRABAJO SE CENTRA EN CONSTRUIR UN MODELO QUE SE AJUSTE A LA REALIDAD

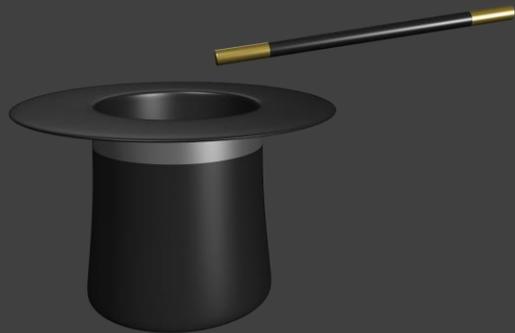


EL RETO ESTÁ CUANDO NO TIENES NI IDEA DE A QUE TE ENFRENTAS DE ANTEMANO (LO QUE SUELE PASAR EN LA VIDA REAL)



TRADICIONALMENTE SE HA PRESTADO MENOS ATENCIÓN A ESTA FAMILIA DE ALGORITMOS YA QUE HA DADO PEORES RESULTADOS QUE LOS MODELOS "INTUITIVOS"

¿Dónde está
el truco?



AUNQUE REQUIERA MENOS
ITERACIONES CON EL ENTORNO
SUELE DEMANDER MÁS “CEREBRO”
(MÁS PODER DE CALCULO)



CUANDO LOS MODELOS HAY QUE
APRENDERLOS SUELEN TENER
SESGOS.....



....Y LOS AGENTES, TANTO DE RL
COMO DE PLANNING, LES ENCANTA
EXPLOTAR ESOS SEGSOS EN LOS
MODELOS....



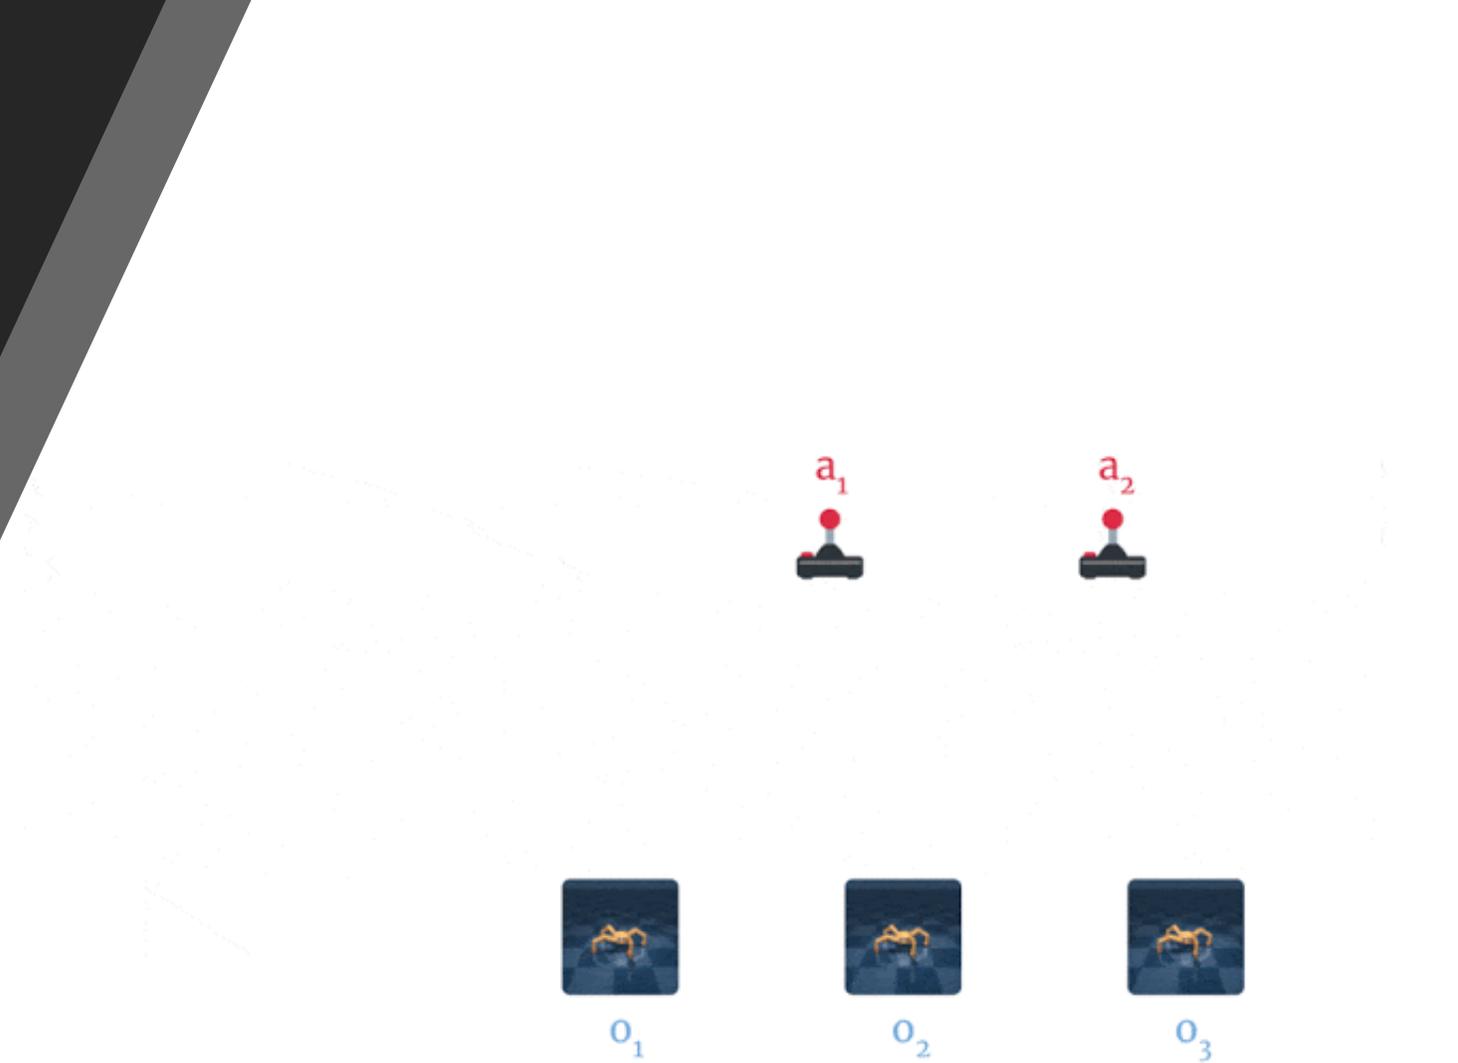
Estado del Arte

Cuando no conocemos el modelo y trabajamos con imagenes

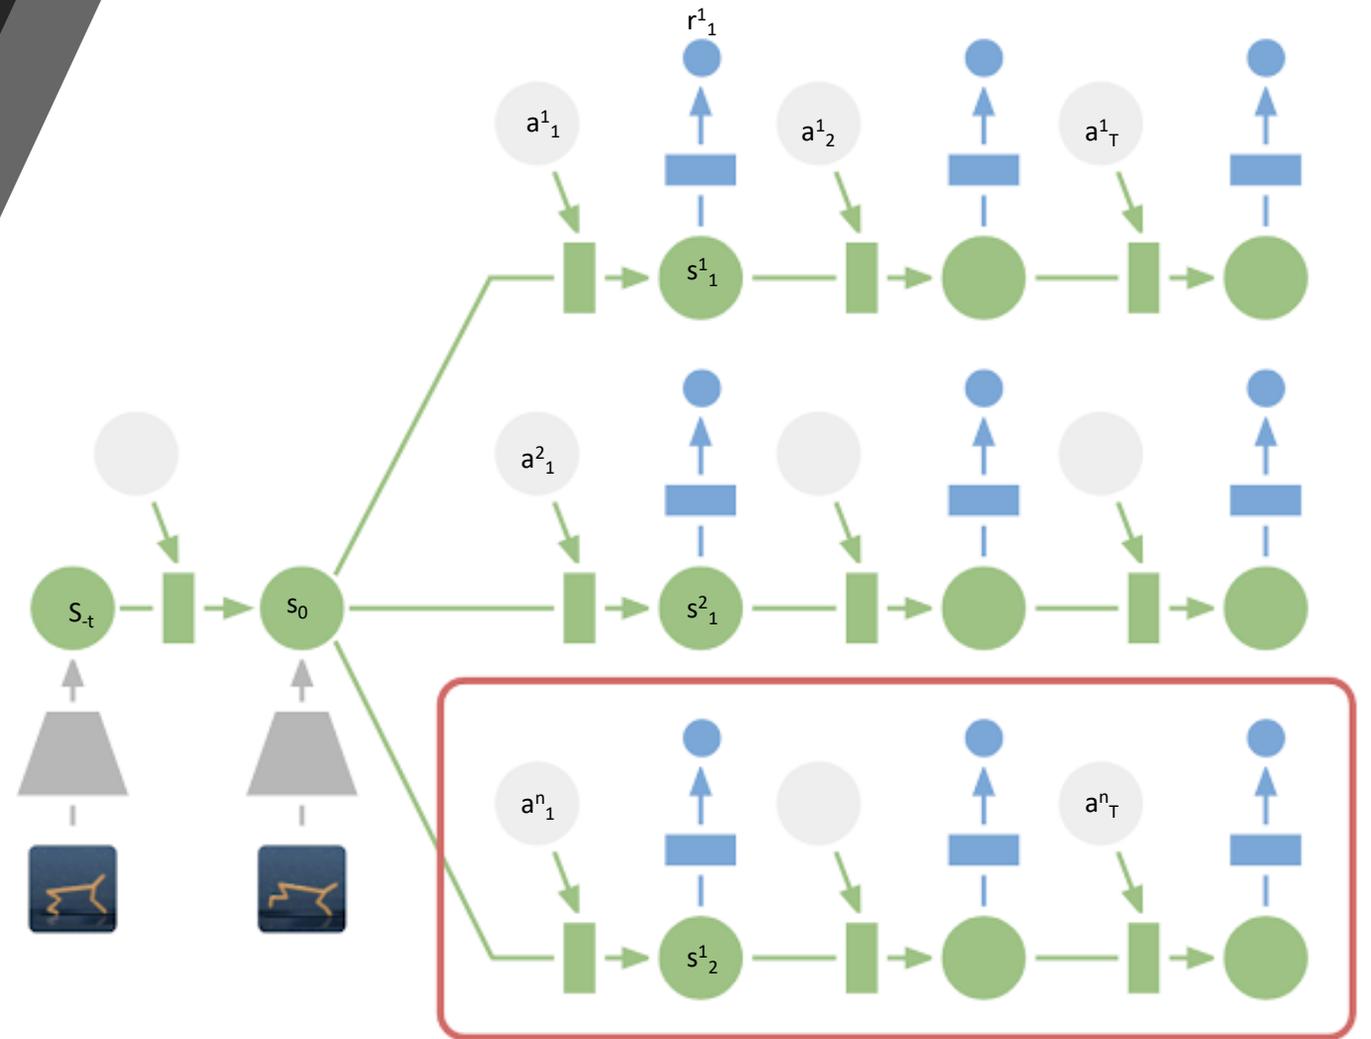
Visual Model-Based Reinforcement Learning as a Path towards Generalist Robots



PlaNet: A Deep Planning Network for Reinforcement Learning

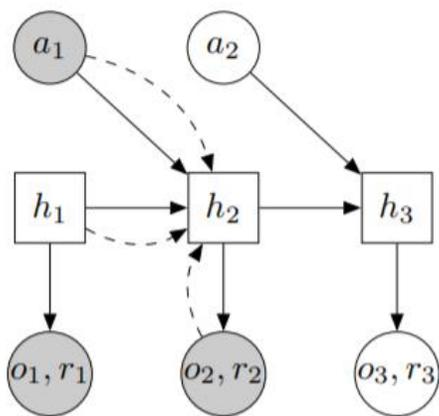


PlaNet: A Deep Planning Network for Reinforcement Learning

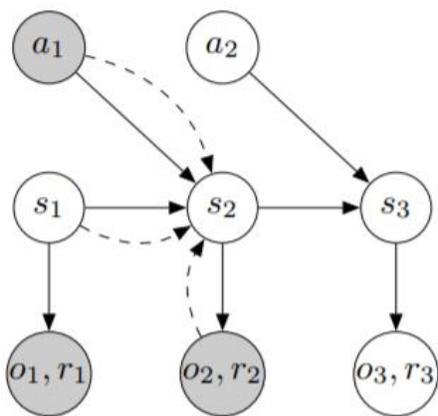


PlaNet: A Deep Planning Network for Reinforcement Learning

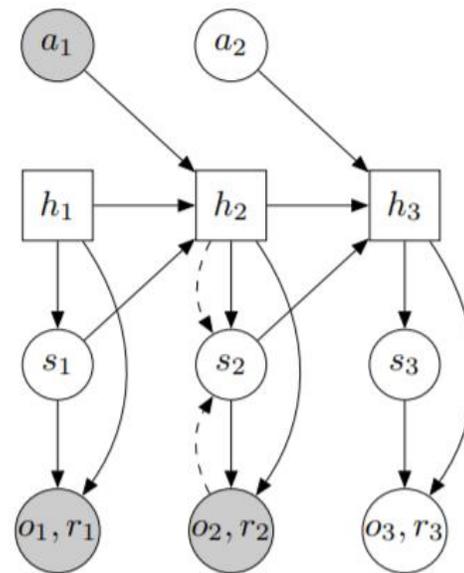
Learning Latent Dynamics for Planning from Pixels



(a) Deterministic model (RNN)

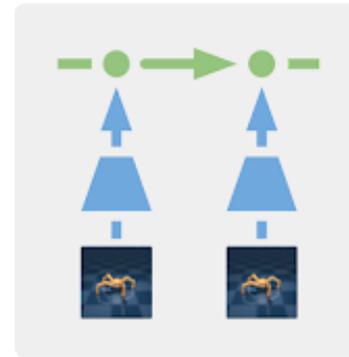


(b) Stochastic model (SSM)

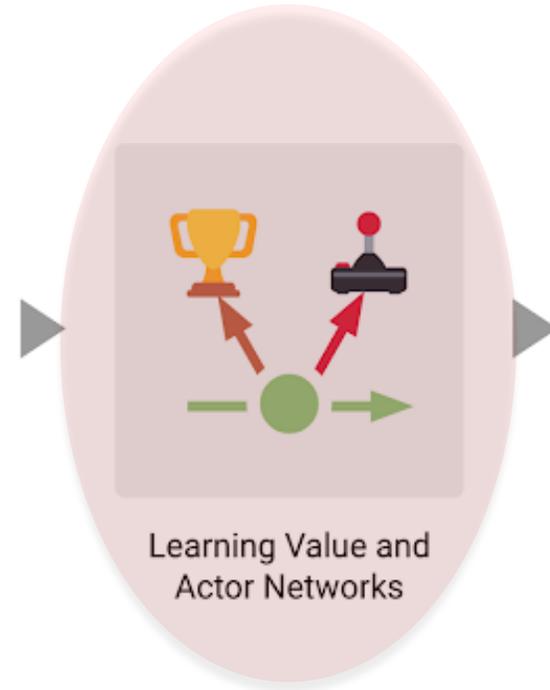


(c) Recurrent state-space model (RSSM)

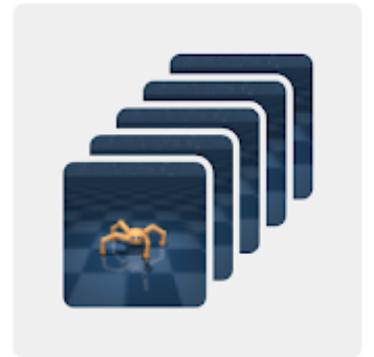
Dreamer: Scalable Reinforcement Learning Using World Models



World Model
Learning



Learning Value and
Actor Networks



Environment
Interaction

Dreamer: Scalable Reinforcement Learning Using World Models



encode images

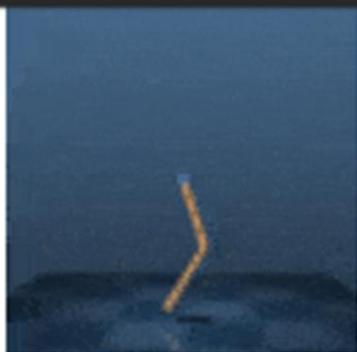


o_1

Algunos resultados



Sparse Cartpole



Acrobot Swingup



Hopper Hop



Walker Run



Quadruped Run



Boxing



Freeway



Frostbite

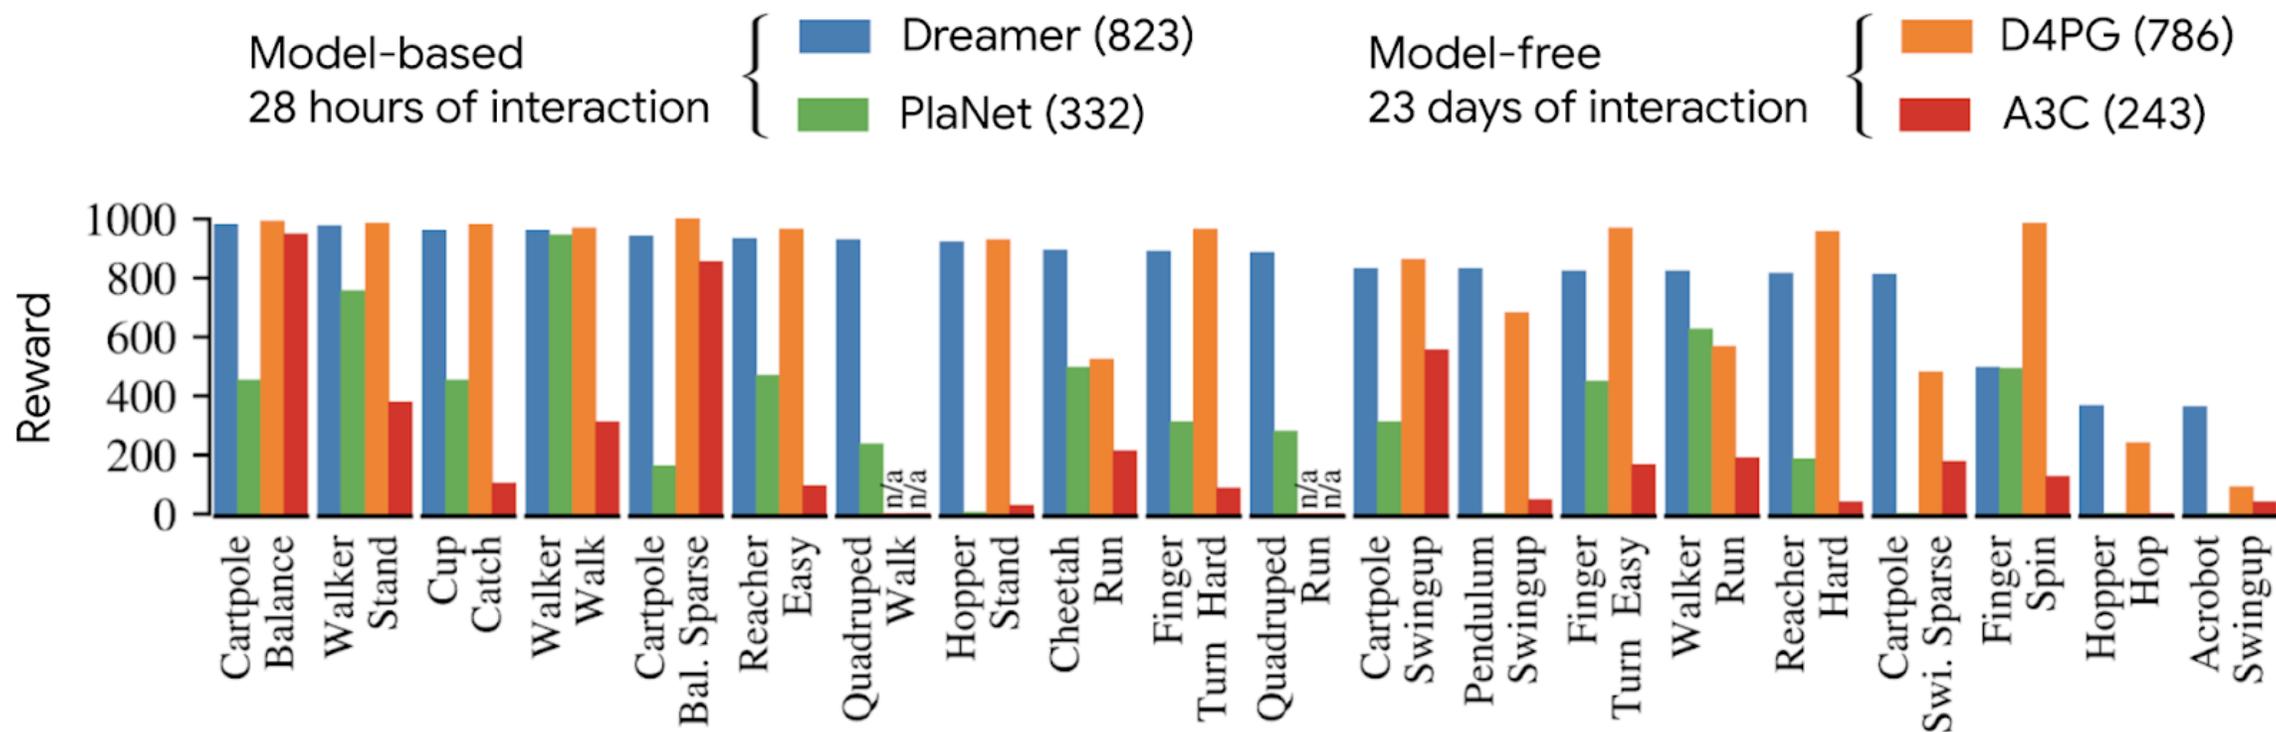


Collect Objects

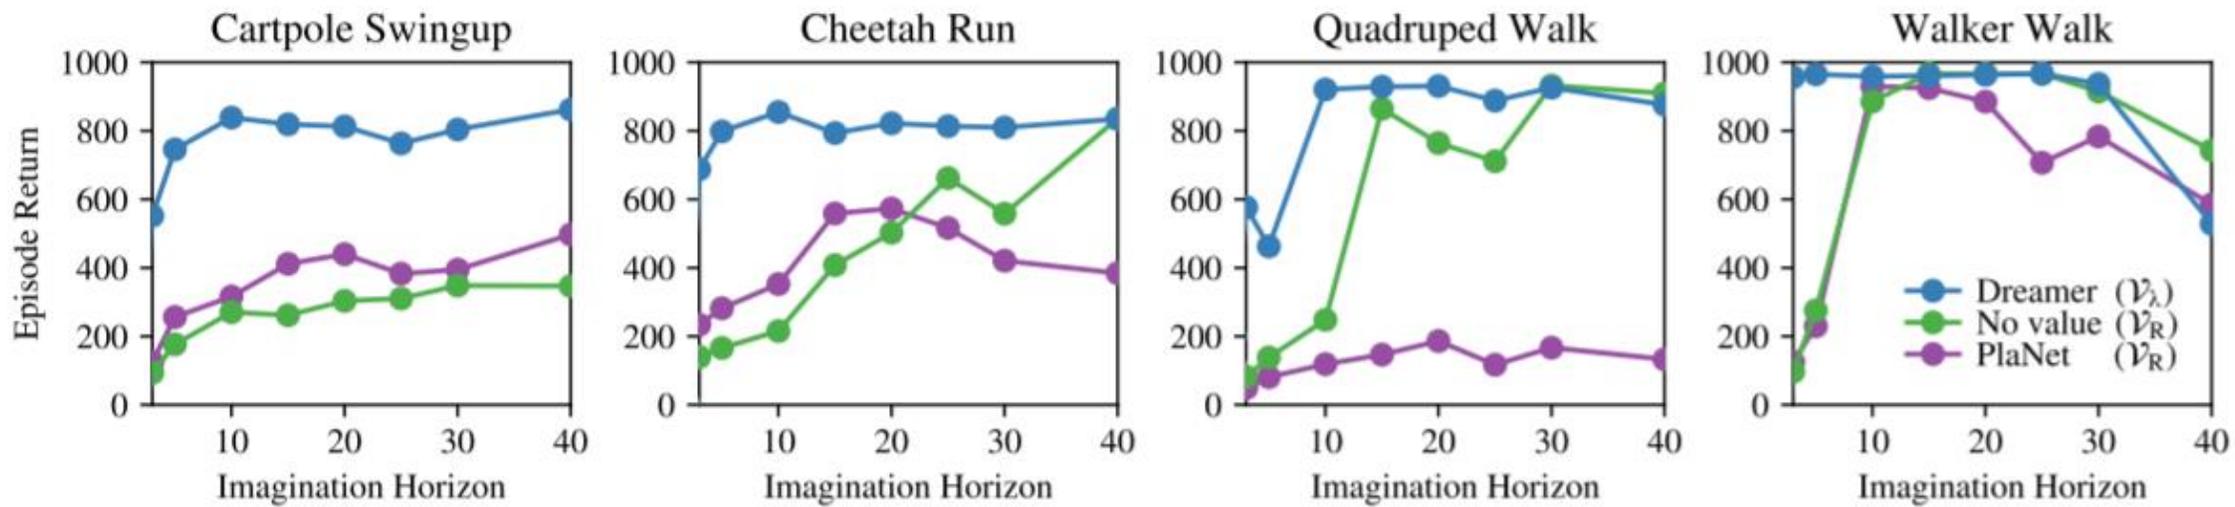


Watermaze

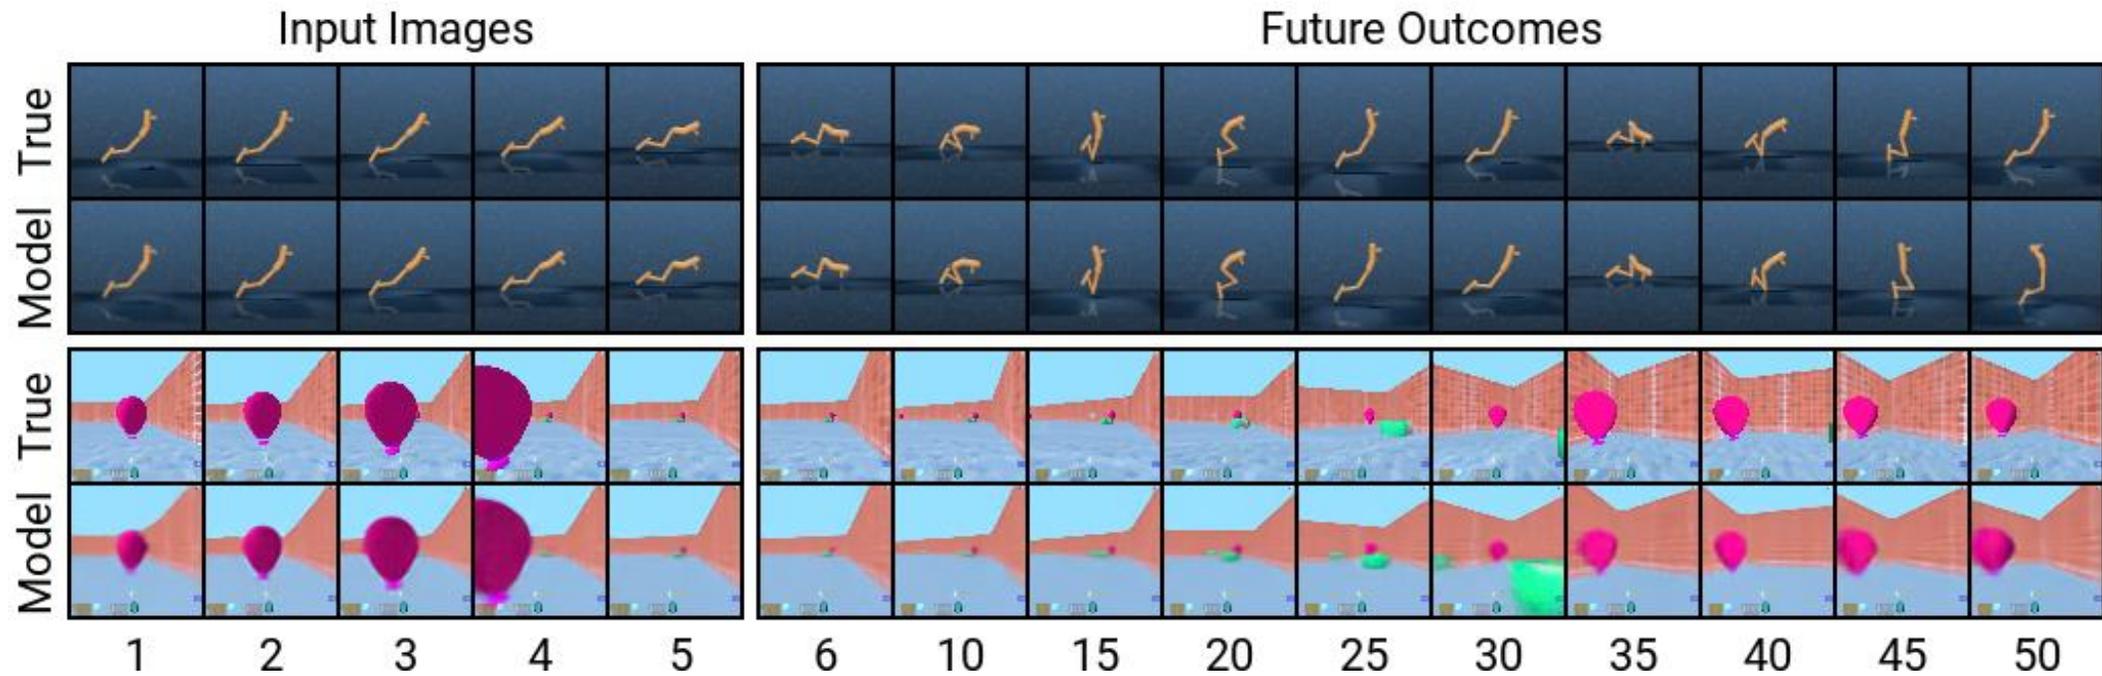
Algunos resultados



Algunos resultados



Siempre podemos ver que “imaginaba”



Para más detalle

- **PlaNet:** Hafner, D., Lillicrap, T., Fischer, I., Villegas, R., Ha, D., Lee, H., & Davidson, J. (2018). Learning latent dynamics for planning from pixels. *arXiv preprint arXiv:1811.04551*.
- **Dreamer:** Hafner, D., Lillicrap, T., Ba, J., & Norouzi, M. (2019). Dream to control: Learning behaviors by latent imagination. *arXiv preprint arXiv:1912.01603*.



¿Preguntas?



@borruell