

Uso de simuladores para el entrenamiento de robots mediante aprendizaje por refuerzo

Gonzalo Zabala

Centro de Altos Estudios en Tecnología Informática (CAETI) · Facultad de Tecnología Informática · Universidad Abierta Interamericana

Gonzalo.Zabala@uai.edu.ar

RESUMEN

El desarrollo exponencial del aprendizaje automático ha atravesado todas las áreas de la actividad humana. En robótica, entrenar el comportamiento de un robot en ambientes dinámicos mediante estos mecanismos se convirtió en una herramienta de gran utilidad para acelerar su desarrollo.

Tradicionalmente, la programación de la interacción de un robot con su ambiente se basaba en modelos matemáticos y heurísticas con testeos engorrosos y permanentes. Los métodos de aprendizaje automático permitieron un entrenamiento menos dependiente de conocimientos previos, generando comportamientos novedosos.

El surgimiento de simuladores con motores de física de alta calidad permitió recrear espacios de entrenamiento con alto grado de realismo. El modelo obtenido es luego transferido al robot físico con un refinamiento posterior acotado.

CONTEXTO

El proyecto está radicado en el Centro de Altos Estudios en Tecnología Informática (CAETI), dependiente de la Facultad de Tecnología Informática de la Universidad Abierta Interamericana. Se inserta en la línea de investigación 'Automatización y robótica'. El financiamiento es brindado por la misma Universidad Abierta Interamericana.

PALABRAS CLAVE

Robótica

Simulación 3D

Machine Learning

Reinforcement Learning




Fig. 1 - Robot entrenado mediante aprendizaje por refuerzo

FORMACION DE RECURSOS HUMANOS

El equipo de trabajo está conformado por:

- Investigador adjunto del CAETI
Director del proyecto
- Tres ayudantes alumnos de la Facultad de Tecnología Informática de la UAI

INTRODUCCION

El aprendizaje por refuerzo (AR) ha surgido como técnica esencial para el entrenamiento de robots, permitiéndoles adquirir comportamientos complejos y adaptarse a entornos reales. El AR permite aprender habilidades en forma autónoma a partir de los datos de sensores y la evaluación de resultados.

En robots móviles, el AR es eficaz para problemas con fricción y contacto, difíciles para los métodos de control convencionales. Sin embargo, realizar el entrenamiento mediante manipulación humana de un robot es imposible y peligroso para el dispositivo y su operario.

El uso de simuladores ha demostrado ser muy prometedor:
+ Recopilación de datos de entrenamiento en forma segura
+ Evita costos y riesgos del mundo real
+ Permite reiniciar el ambiente en milisegundos
+ Miles de iteraciones por hora sin desgaste físico

Principal desafío — brecha simulación-realidad:

- El rendimiento real presenta diferencias con el mundo simulado
- Técnicas de aleatorización de dominios para reducirla
- Aprendizaje por imitación para mejorar la transferencia
- RL-CycleGAN: traducción automática de imágenes simuladas a imágenes realistas.

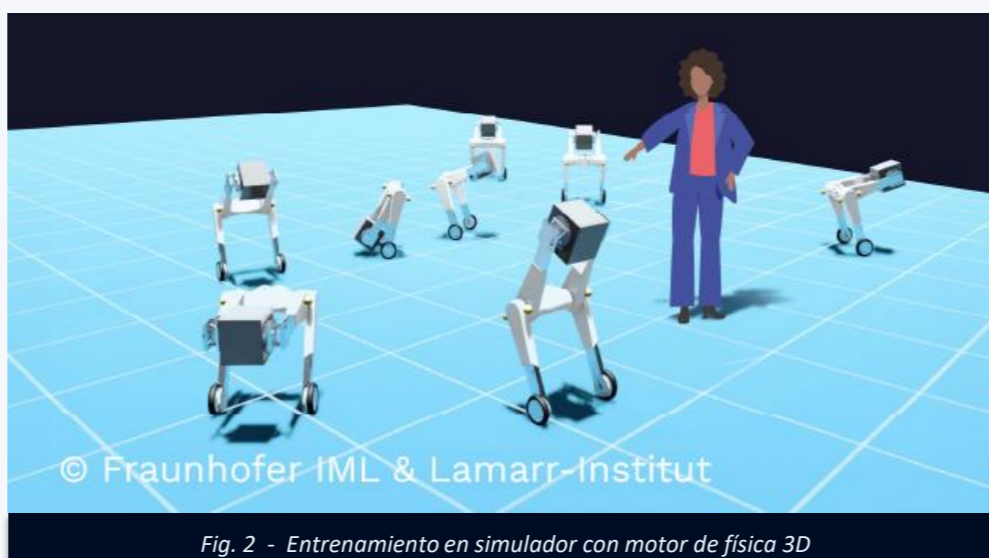


Fig. 2 - Entrenamiento en simulador con motor de física 3D

LINEAS DE INVESTIGACION Y DESARROLLO

1. Mapeo sistemático del estado del arte:
Aspectos esenciales del AR en robots, simuladores y técnicas predominantes, autores e instituciones líderes.
2. Comparación de simuladores:
Criterios objetivos de elección para optimizar la eficiencia del entrenamiento y la transferencia real.
3. Experiencia en Rescate (RoboCup):
Construcción del ambiente, definición de la red neuronal e implementación de la técnica de AR seleccionada.
4. Experiencia en Fútbol de robots:
Navegación en sistemas dinámicos y entrenamiento de comportamientos colaborativos multi-agente.
5. Validación Sim-to-Real:
Ambientes simulados y físicos paralelos para evaluar técnicas de reducción del gap entre mundos.

RESULTADOS OBTENIDOS / ESPERADOS

1. Mapeo sistemático

Identificación de las principales tendencias en el entrenamiento de robots mediante AR: simuladores más utilizados, técnicas predominantes, autores e instituciones con mayor producción científica y conferencias de referencia en el área.

2. Entrenamiento en Rescate

Construcción de un ambiente de simulación para RoboCup Rescue, selección del robot, definición de la red neuronal e implementación de la técnica de AR. El robot aprenderá a navegar en condiciones de fricción y contacto con comportamientos adaptativos.

3. Entrenamiento en Fútbol

Entrenamiento en dos etapas: navegación individual en sistemas altamente dinámicos y comportamiento colaborativo multi-agente. Los robots optimizarán su respuesta ante cambios rápidos y la eficiencia en tareas colectivas.

4. Validación Sim-to-Real

Implementación paralela de ambientes simulados y físicos para evaluar la efectividad de las técnicas de reducción del gap. Análisis comparativo cuantitativo entre el modelo entrenado en simulación y su desempeño en el mundo real.

WICC 2026

Workshop de Investigadores
en Ciencias de la Computación
Marzo 2026

BIBLIOGRAFIA SELECCIONADA

Cutler & How (2015). Efficient RL for robots using informative simulated priors. ICRA. Ibarz et al. (2021). How to train your robot with deep RL: lessons learned. IJRR. Johannink et al. (2019). Residual Reinforcement Learning for Robot Control. ICRA. Ju et al. (2022). Transferring policy of deep RL from simulation to reality. Nature MI. Kim et al. (2021). A Survey on Simulation Environments for Reinforcement Learning. UR. Kormushev et al. (2013). Reinforcement Learning in Robotics: Applications. Robotics.

Liang et al. (2018). GPU-Accelerated Robotic Simulation for Distributed RL. CoRL. Lin (1992). Reinforcement learning for robots using neural networks. CMU. Rao et al. (2020). RL-CycleGAN: Reinforcement Learning Aware Sim-to-Real. CVPR. Salvato et al. (2021). Crossing the Reality Gap: Survey on Sim-to-Real RL. IEEE Access. Zhao et al. (2020). Sim-to-Real Transfer in Deep RL for Robotics: A Survey. SSCI. Zhu et al. (2023). Survey of Sim-to-Real Transfer for Bioinspired Robots. IEEE TNNLS.