

Modelos de Machine Learning para Vehículos Autónomos aplicados a la Detección de Obstáculos en Centros de Logística

Débora Denise Altamirano Medina¹, Augusto Guillermo Tapparelli¹,
Matías Kreder¹ y Pablo Ezequiel Inchausti¹

¹ Universidad Argentina de la Empresa (UADE),
Instituto de Tecnología (INTEC). Buenos Aires, Argentina
{daltamirano, atapparelli, mkreder, pinchausti}@uade.edu.ar

Abstract. Los autos autónomos cada día están tomando mayor importancia y su utilización se ha extendido a varias industrias. Un ejemplo del impacto que se puede lograr por medio de robot automatizados puede observarse en Amazon y la operación automatizada en sus centros de almacenamiento y distribución de mercadería. Pero realizar investigaciones asociadas a vehículos autónomos requiere de un ecosistema complejo, con simuladores virtuales, vehículos a escala, entornos controlados y una adecuada configuración de dispositivos que permita la experimentación sobre una versión simplificada de la realidad. En ese contexto, se propone utilizar a la plataforma de AWS DeepRacer con sus entornos físicos y virtuales, como medio de investigación de soluciones para los centros de logística. Se proponen tres objetivos operativos con distinto grado de soporte nativo en la plataforma, estos son en los centros de logística: esquivar obstáculos, desplazar objetos y alertar sobre líquidos. Para el entrenamiento de los modelos de machine learning se propone utilizar aprendizaje por refuerzo.

Keywords: Vehículos Autónomos, Machine Learning, Reinforce Learning.

1. Introducción

Con el avance de la tecnología, la posibilidad de que las máquinas actúen de forma autónoma tiene cada vez más relevancia. En el caso de la industria automotriz, el avance de la inteligencia artificial y la eficiencia en la velocidad de procesamiento de los dispositivos ha logrado que disminuir la necesidad de la interacción humana a tal punto que la posibilidad de autos completamente autónomos ya son una realidad.

Se entiende como autos autónomos a vehículos que tienen la capacidad de percibir el entorno que lo rodea y navegar a través del ambiente de forma segura con poca o sin interacción humana [1], y, de acuerdo al grado de autonomía del vehículo, *SAE International* definió una escala de cinco niveles, en donde el Nivel 0 carece de automatizaciones con el conductor realizando todas las acciones, y el Nivel 5 completamente automatizado en donde el conductor solamente establece el destino y el vehículo realiza todas las acciones sin restricciones. [2]

Para lograr el grado de autonomía de Nivel 5, los vehículos incorporan sensores propioceptivos, es decir, del su estado interno, como la fuerza, energía, voltajes, carga, radio de ángulos, etc. Por ejemplo, utilizando los sistemas de navegación (GNSS y GPS), las unidades de medida inercial (IMU) y los acelerómetros, giroscopios y magnetómetros. También disponen de sensores exteroceptivos, es decir, de su estado

externo, como ser cámaras, radares, sensores ultrasónicos y el LiDAR que permite detectar obstáculos por medio de la emisión de un láser [1].

Entre los casos de uso más difundidos que buscan garantizar la seguridad de los vehículos autónomos se encuentran los recorridos de buses autónomos sobre circuitos controlados, y los centros de logística [3]. Se puede destacar el grado de automatismo en los almacenes de la tienda Amazon, con el robot *Proteus* completamente autónomo capaz de desplazar cargas, y operar no solo dentro de una zona de seguridad, sino que es capaz de compartir el área de trabajo con las personas y esquivarlas [4].

En el presente trabajo se investiga sobre el desarrollo de modelos de *machine learning (ML)* para vehículos autónomos, y considera a los centros de logística como el escenario de aplicación.

Para realizar el desarrollo sobre un entorno simulado físico y un entorno virtual se propone utilizar la plataforma AWS DeepRacer de Amazon que ofrece vehículos autónomos a escala 1:18 equipados con los dispositivos y sensores necesarios, entre ellos las cámaras y el LiDAR. [5]

El presente trabajo se corresponde al Proyecto Final de Ingeniería Informática (PFI) de Débora Altamirano y Augusto Tapparelli en curso durante 2023 y se integra dentro del INTEC, el Instituto de Tecnología de UADE, al proyecto de investigación *A21T08 Aplicaciones de Machine Learning y IoT sobre Vehículos Autónomos*.

1.1 Objetivos

Se define como el objetivo principal, desarrollar modelos de *Machine Learning* para permitir a un vehículo autónomo realizar diversas funciones aplicables a centros de logística, para el territorio argentino en el año 2023.

Y para lograr el objetivo principal se propone, como objetivos específicos, desarrollar los siguientes tres modelos de ML:

- Modelo de ML para identificar y esquivar obstáculos.
- Modelo de ML que permita identificar y desplazar objetos.
- Modelo de ML que permita identificar líquidos y notificar.

1.2 Alcance

En términos de alcance, se propone utilizar la plataforma AWS DeepRacer para probar el desempeño de los modelos de *machine learning*, utilizando tanto el entorno virtual para evaluar los modelos, como el entorno físico utilizando los vehículos AWS DeepRacer EVO y la pista con el circuito de recorrido y la posibilidad de incorporar obstáculos en el camino [5]. Respecto al método de entrenamiento, se utiliza en los modelos de ML el aprendizaje por refuerzo, con funciones de recompensa con la premisa de maximizar el premio para el agente si se acerca al objetivo.

2. Materiales y Métodos

Para el desarrollo de los modelos de ML y los algoritmos de aprendizaje por refuerzo, se utiliza la plataforma AWS DeepRacer, tanto en el mundo físico, con el vehículo AWS DeepRacer EVO y la pista de entrenamiento, y los simuladores virtuales. El vehículo AWS DeepRacer EVO está equipado con dos cámaras de 4MP para su visión periférica, cuenta con sensores de aceleración y el giroscopio, y el sensor LiDAR para la identificación de objetos. Respecto a su CPU, tiene un procesador *Intel Atom* con 4GB de memoria RAM y 32 GB de almacenamiento para alojar y ejecutar los modelos entrenados que controlan el dispositivo [6]

Para la simulación en el entorno físico, se utiliza el modelo de pista denominado *A to Z Speedway* con dimensiones de 5.48m x 8.22m [7], y que puede observarse desplegada en la Fig. 1 junto a uno de los vehículos utilizados. La impresión de la pista se realizó con la gestión del departamento de informática, sobre una malla de vinilo con colores mate para minimizar el brillo. También se colocan las barreras laterales, recomendado de color azul para que el vehículo identifique el fin de la pista.



Fig. 1: Vehículo AWS DeepRacer Evo y pista en las instalaciones de UADE

Respecto al entorno virtual, se utiliza el simulador provisto por la plataforma AWS DeepRacer, que permite seleccionar distintos tipos de circuitos y además incorporar obstáculos dentro del recorrido para generar distintos escenarios de entrenamiento.

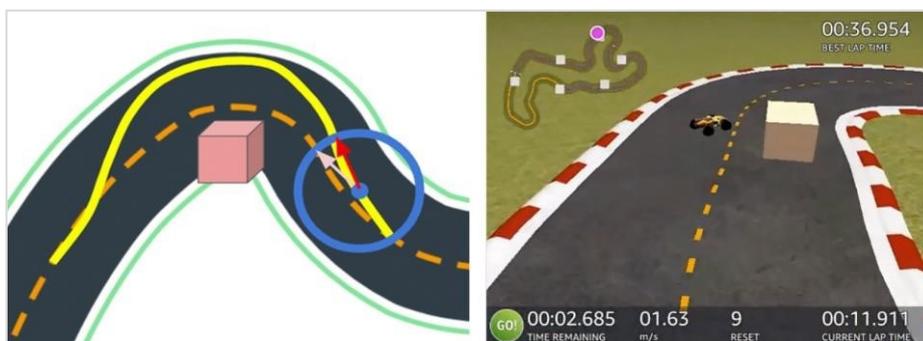


Fig. 2: Emulador virtual en la plataforma AWS DeepRacer con obstáculos [8]

2.1 Entrenamiento de los Modelos de Machine Learning

Para la fase de entrenamiento de los modelos de ML, se utiliza la plataforma *Deep Racer For Cloud (DRFC)* que permite entrenar los modelos de ML de DeepRacer en la nube, localmente en Windows, Linux o Mac. [9]

El entrenamiento se realiza sobre instancias EC2 *spot* de AWS. Las instancias *spot* utilizan capacidad ociosa de AWS y permiten reducir los costos de uso al mínimo. La instancia *spot* utilizada es una *c5.2xlarge* a un costo de usd 0,34 por hora. Se prevé utilizar en el futuro instancias *spot* EC2 con GPU de mayores prestaciones, aunque también mayores costos. En la Fig. 3 se observa una demostración de *Deep Racer For Cloud (DRFC)* realizada a los alumnos de PFI con tres *workers* para el entrenamiento.

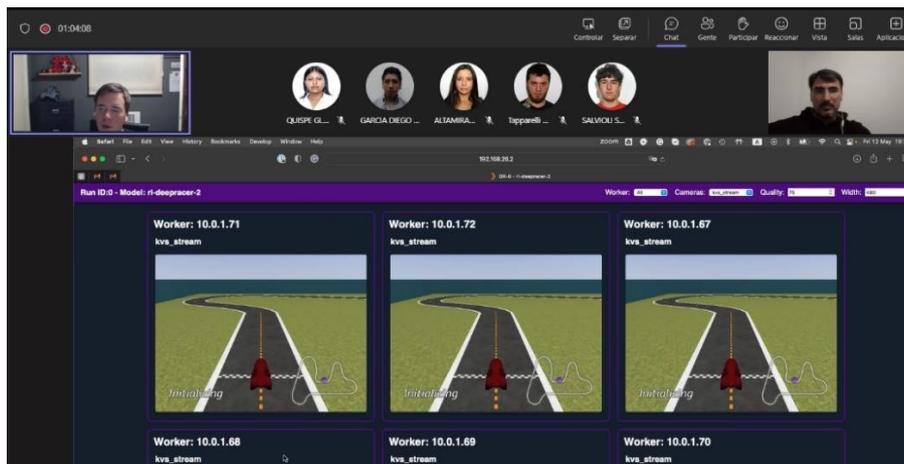


Fig. 3: Demostración del uso de *Deep Racer For Cloud (DRFC)* con alumnos de PFI UADE

Para el desarrollo de los modelos de ML, se utiliza *Python* para programar los algoritmos de aprendizaje por refuerzo, alineados a los tres objetivos específicos propuestos: capacidad de esquivar obstáculos, desplazar objetos y alerta de líquidos.

En el aprendizaje por refuerzo, un agente inteligente realiza acciones en su entorno que son premiadas o no por una función de recompensa, en la medida que el estado del agente se acerca su objetivo.

En el caso de uso de esquivar obstáculos, la plataforma AWS DeepRacer ofrece soporte para el desarrollo y evaluación de las funciones de recompensa. Y en el contexto del presente trabajo se desarrollarán métodos de optimización de modelos. En los casos de uso de desplazar objetos, y detección de líquidos, la plataforma de AWS DeepRacer no ofrece soporte nativo, con lo cual se prevé desarrollar funciones de recompensa que se integren a modelos de reconocimientos de imágenes para identificar tanto los líquidos con el fin de generar una alerta, como los objetos desplazables, con el fin de iniciar una acción de movimiento y traslado a destino.

En el presente estado de avance del PFI, que se encuentra al presente en curso, los detalles de la problemática de desplazamiento de objetos y detección líquidos se encuentran en investigación y desarrollo.

3. Conclusiones y discusión

La investigación aplicada a modelos de ML para vehículos autónomos ofrece la oportunidad de mejorar la eficiencia de los procesos productivos de la industria. Entre los campos de aplicación, los almacenes y centros de logística se presentan como un sector estrechamente relacionado con la automatización de sus operaciones. En particular, la investigación sobre vehículos autónomos requiere de entornos controlados para garantizar la seguridad. También, al simplificar la realidad es posible focalizar en la construcción de procesos escalables de aprendizaje automatizado. En ese contexto de necesidad de entornos físicos o virtuales, la plataforma AWS DeepRacer se presenta como una alternativa por el equipamiento inicial ofrecido, desde los simuladores hasta los vehículos autónomos completamente equipados. Es cierto que la plataforma se orienta a la competición en velocidad, y la falta de soporte nativo hace complejo alcanzar ciertas acciones. Pero la integración de la plataforma AWS DeepRacer con otras tecnologías de ML, como el reconocimiento de imágenes, habilita un nuevo campo para la construcción y el diseño de soluciones.

Agradecimientos. A la Facultad de Ingeniería y Ciencias Exactas (FAIN) y al Instituto de Tecnología (INTEC) de la Universidad Argentina de la Empresa (UADE) por apoyo a la línea de investigación de “*Aplicaciones de Machine Learning y IoT sobre Vehículos Autónomos*” (A23T08).

Referencias

1. H. Ignatious, H. Sayed, y M. Khan, “An overview of sensors in Autonomous Vehicles”, *Procedia Computer Science*, vol. 198, pp. 736-741, (2022) doi:10.1016/j.procs.2021.12.315.
2. SAE International, “Taxonomy and Definitions for Terms Related to Driving Automation Systems for On-Road Motor Vehicles”. (2021). Accedido: 24/07/2023. https://www.sae.org/standards/content/j3016_202104/.
3. D. Castelló, “Uso de vehículos autónomos y conectados”, (2021). Accedido: 24/07/2023. <https://dallocalas.blogs.upv.es/2021/04/25/uso-de-vehiculos-autonomos-y-conectados/>
4. L. Alcalde. (2022) “Amazon Proteus: así funciona su primer robot totalmente autónomo” <https://www.businessinsider.es/amazon-proteus-funciona-primer-robot-totalmente-autonomo-1081681>. Accedido: 08/08/2023.
5. Amazon Web Services, Inc., “¿Qué es AWS DeepRacer?”, (2023). Accedido: 07/08/2023. https://docs.aws.amazon.com/es_es/deepracer/latest/developerguide/what-is-deepracer.html
6. Amazon Web Services, Inc., “AWS DeepRacer, la manera más rápida de iniciarse en aprendizaje automático”, <https://aws.amazon.com/es/deepracer>. Accedido: 07/08/2023.
7. Amazon Web Services, Inc., “AWS DeepRacer track design templates”. <https://docs.aws.amazon.com/deepracer/latest/developerguide/deepracer-track-examples.html>
8. B. Turner, “Bandwidth R&D’s AWS DeepRacer 2021 Season Recap”, *Bandwidth*, (2022). <https://www.bandwidth.com/blog/bandwidth-rd-aws-deepracer-2021-season-recap/>
aws-deepracer-community, “Deepracer-for-Cloud”, (2023) <https://aws-deepracer-community.github.io/deepracer-for-cloud/>. Accedido: 05/08/2023.