

Sistema de ubicación y reconocimiento de objetos para robot autónomo.

Object recognition and location system for autonomous robot.

Alvaro Hernández Sol* (1).
Tecnológico Nacional de México campus Tuxtla Gutiérrez.
alvarohs@tuxtla.tecnm.mx.

Manuel de Jesús Cancino Escobar (2). Estudiante del Tecnológico Nacional de México campus Tuxtla Gutiérrez,
manuelcancino883@outlook.com.

Raúl Moreno Rincón (3). Tecnológico Nacional de México campus Tuxtla Gutiérrez, rmoreno@tuxtla.tecnm.mx.

José Ángel Zepeda Hernández (4). Tecnológico Nacional de México campus Tuxtla Gutiérrez,
jzepeda@tuxtla.tecnm.mx.

Aldo Esteban Aguilar Castillejos (5). Tecnológico Nacional de México campus Tuxtla Gutiérrez,
aaguilarc@tuxtla.tecnm.mx.

Osbaldo Ysaac García Ramos (6). Tecnológico Nacional de México campus Tuxtla Gutiérrez,
ogarcia@tuxtla.tecnm.mx.

*corresponding author.

Artículo recibido en septiembre 27, 2021; aceptado en octubre 13, 2021.

Resumen.

El presente artículo describe el diseño de un sistema de reconocimiento y ubicación de objetos usando sensores ultrasónicos aplicados a un robot móvil autónomo. Al aplicar este sistema en el prototipo se le proporciona la capacidad de reconocer y ubicar la posición de dicho objeto con la finalidad de poder evadirlo y generar mapas de posición de obstáculos en ambientes semiestructurados. En el reconocimiento de los objetos se utiliza una matriz de nueve sensores ultrasónicos, que incrementa la cantidad de datos a 27 por lectura, controlando su dirección. Estos datos son usados como entradas a una red neuronal artificial "Deep learning", entrenada para realizar el reconocimiento de los diferentes objetos a seleccionar. En pruebas de laboratorio se obtuvieron buenos resultados en el reconocimiento de objetos ubicados hasta una distancia máxima de 50 cm. Al implementar la red en el prototipo robótico este se deberá desarrollar en un ambiente controlado en el cual pueda identificar qué tipo de objeto tiene cerca y así poder ubicarlo dentro de un mapa de entorno.

Palabras clave: Robot, redes neuronales artificiales, reconocimiento de patrones, sensor ultrasónico.

Abstract.

This article describes the design of an object recognition and location system using ultrasonic sensors applied to an autonomous mobile robot. By applying this system in the prototype, it is provided the ability to recognize and locate the position of said object in order to be able to evade it and generate obstacle position maps in semi-structured environments. In the recognition of the objects, a matrix of nine ultrasonic sensors is used, which increases the

amount of data to 27 for reading, controlling its direction. These data are used as inputs to an artificial neural network "Deep learning", trained to recognize the different objects to be selected. In laboratory tests, good results were obtained in the recognition of objects located up to a maximum distance of 50 cm. When implementing the network in the robotic prototype, it must be developed in a controlled environment in which it can identify what type of object is nearby and thus be able to locate it within an environment map.

Keywords: Robot, Artificial Neural Networks, Pattern Recognition, Ultrasonic sensor.

1. Introducción.

La robótica móvil autónoma es un tema de investigación fascinante, por muchas razones. Primero, cambiar un robot móvil de una computadora con ruedas que simplemente es capaz de sentir algunas propiedades físicas del medio ambiente a través de sus sensores en un agente inteligente, capaz de identificar características, detectar patrones y regularidades, aprender de la experiencia, localizar, construir mapas y navegar requiere la aplicación simultánea de muchas disciplinas de investigación (Rios, 2015).

Rodríguez (2015) menciona que “La autonomía de un robot se ve definida por su capacidad de reaccionar ante los acontecimientos que surgen a su alrededor, para ello se debe tener un sistema estable y robusto el cual resuelva de la mejor manera tales circunstancias”. Para el desarrollo de este artículo se basó en un sistema el cual mediante redes neuronales artificiales detecta características específicas de objetos físicos como cuadrados y cilindros, para lograr esto el prototipo robótico cuenta con una serie de sensores ultrasónicos que le permiten “ver” su entorno, estos sensores funcionan como datos de entrada para el prototipo robótico.

Una red neuronal (también llamada red neuronal artificial) siendo un sistema adaptativo semejante al cerebro humano, que aprende mediante el uso de nodos (neuronas) interconectados en una estructura estratificada. Las redes neuronales son especialmente adecuadas para realizar el reconocimiento de patrones para clasificación de objetos o señales en los sistemas de control, visión y habla (García, 2017).

Una de las técnicas de machine learning para llevar a cabo la clasificación de características físicas de objetos presentados a un robot son los sistemas de aprendizaje supervisado. Estos toman un conjunto de datos de una colección de ejemplos etiquetados $\{(x_i, y_i)\}^{N_i} = 1$. Usados para producir un modelo que, a partir de un vector de entrada x_i , consiga deducir una etiqueta y_i correspondiente al vector de características (Gonzalo, 2019).

El aprendizaje profundo (Deep Learning) es una técnica de aprendizaje automático que enseña a las computadoras a hacer lo que es natural para los humanos: aprender con el ejemplo. El aprendizaje profundo es una tecnología clave detrás de los automóviles sin conductor, que les permite reconocer una señal de alto o distinguir a un peatón de una farola. Los modelos de aprendizaje profundo pueden lograr una precisión de vanguardia, a veces superando el rendimiento a nivel humano. Los modelos se entrenan mediante el uso de un gran conjunto de datos etiquetados y arquitecturas de redes neuronales que contienen cientos de capas (Valencia, 2016).

2. Métodos.

Deep Learning.

En el aprendizaje profundo, un modelo de computadora aprende a realizar tareas de clasificación directamente a partir de imágenes, texto o sonido. Los modelos de aprendizaje profundo pueden lograr una precisión de vanguardia, a veces superando el rendimiento a nivel humano. Los modelos se entrenan mediante el uso de un gran conjunto de datos etiquetados y arquitecturas de redes neuronales que contienen muchas capas, para el desarrollo de una red neuronal artificial se utilizó el Toolbox de Matlab “Deep Learning”. (The Mathworks, 2021).

Como menciona Goodfellow, los modelos de Deep learning utilizados están basados en las redes profundas de retro propagación, también llamadas “redes neuronales de retro propagación”. La finalidad de estas redes es aproximar un función f^* por medio de un clasificador $y = f^*(x)$ convirtiendo una entrada x a una categoría y definiendo esta transformación como $y = f(x; \theta)$.

Como podemos representar una red neuronal como una composición de funciones diferentes, dependiendo de la cantidad de funciones dependerá la profundidad de la red neuronal.

$$f(x) = f^{(3)}(f^{(2)}(f^{(1)}(x)))$$

Siendo $f(1)$ la capa de entrada, $f(2)$ la segunda capa y $f(3)$ la capa de salida. Cada una de estas funciones las podemos representar como un vector.

Un algoritmo de hipótesis final como el presentado por Abu-Mostafa (2012), nos menciona que para una función objetivo desconocida (como fórmula aproximada de manera ideal).

$$f : x \rightarrow y$$

Y teniendo un grupo de ejemplos históricos de objetos caracterizados.

$$(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)$$

Generamos un algoritmo de aprendizaje A , basado en un grupo de reglas hipotéticas H , con las cuales el algoritmo genera un fórmula de aprendizaje como resultado de la aplicación como entrada f .

$$g \approx f$$

Basado en un proceso de optimización que se utiliza para encontrar los valores óptimos w^* y b^* minimizando la expresión de la función objetivo.

$$\frac{1}{N} \sum_{i=1 \dots N} (f_{w,b}(x_i) - y_i)^2$$

Siendo la pérdida promedio, para un modelo, la media de las penalizaciones obtenidas aplicando el modelo al grupo de entrenamiento (Burkov, 2019).

Por esa razón si considerando lo que Sandoval (2018) menciona “si se observa que hay entre un 80% a 90% de respuestas correctas, podemos decir que hay un buen grado de aprendizaje y poder utilizar ese algoritmo”, se toma esta premisa para realizar la selección de la red neuronal a utilizar, la de mejor porcentaje de acierto para la implementación en el prototipo robótico. Con esta herramienta se entrenaron 41 redes neuronales distintas,

Para llevar a cabo este entrenamiento se construyó un robot móvil con ruedas de movimientos independientes. También se montó un sistema de recolección de datos, usando para esto 9 sensores ultrasónicos SRF08.

Para elaborar el chasis se construyó un marco con perfiles de aluminio en forma de C de $1 \times 25 \times 1$ agujeros los cuales tienen una medida de 32 cm de largo y 3 cm de ancho. Quedando un marco con dimensiones de 32 cm de largo y 32 cm de ancho. Se ubicó un motor NEMA17 en la parte central del móvil para colocar una caja de engranajes reductora de tipo planetario, la cual se imprimió, usando PLA, ver figura 1.



Figura 1. Montaje de la caja reductora de engranes helicoidales

Para la sistema de “visión” se construyó una base giratoria de 31cm de diámetro y un grosor de 6 mm del material ABS plástico, siendo esta sujeta por medio de un piñón dentro de la caja de engranes. En esta base se ubicaron los 9 sensores ultrasónicos SRF08, formando un semicírculo en las orilla, cada sensor se colocó con un Angulo de separación de 22.5° , esto con la finalidad de cubrir los 180° de visión que se necesita. Para el montaje de cada sensor se utilizó acrílico transparente cortado a medida, ver figura 2.




Figura 2. Montaje de base giratoria de los sensores ultrasónicos SRF08

Cuando se monta el sistema de visión sobre la estructura del móvil, se agrega la electrónica de control y visualización gráfica, teniendo un sistema como se muestra en la figura 3




Figura 3. Diseño CAD del prototipo robótico

3. Resultados.

Para llevar a cabo el entrenamiento del sistema, se realiza la lectura de 27 muestras por elemento a analizar. El objeto a entrenar se ubica en varias posiciones alrededor del sistema de “visión”, a no más de 50 cm de distancia. Las lecturas se hace en tres rondas, ya que solo se tiene 9 sensores, cada ronda consta de 9 lecturas, guardando estas en memoria, para posteriormente rotar el sistema 7.5°, leer de nuevo y volver a rotar de nuevo los 7.5° y al final de las 27 lecturas se rota en sentido contrario los 15°. Esto se hizo con objetos cilíndricos y cuadrados, De toda la información almacenada se utilizó el 80% para entrenar a las redes neuronales, utilizando el 20% de muestras restante como datos de verificación de eficiencia del clasificador de objetos. Durante el proceso de aprendizaje se entrenaron 42 diferentes redes neuronales de retro propagación, variando las diferentes características (tipo de señal de salida, cantidad de capas y cantidad de neuronas por capa). Buscando incrementar el porcentaje de aciertos en la verificación de la red entrenada. Este incremento se puede observar en la figura 4.

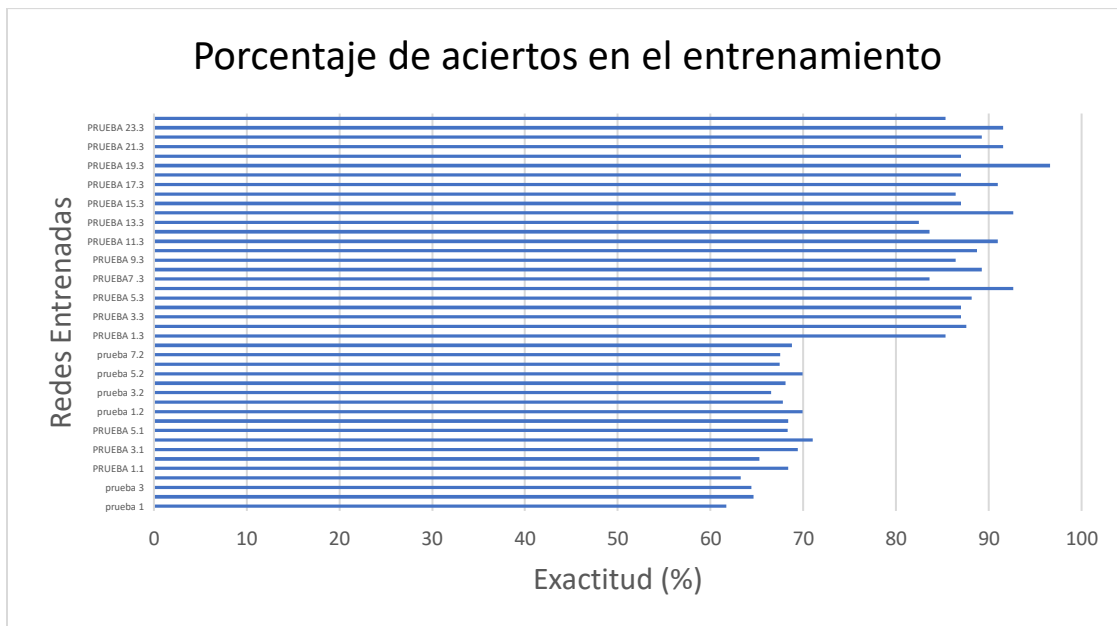


Figura 4. Comparativo de exactitud de todas las redes entrenadas.

Con los resultados obtenidos de la red neuronal artificial que obtuvo el mejor porcentaje de aciertos en el entrenamiento, se programó en el sistema de ubicación y reconocimiento para comprobación de resultados frente a datos de entrada diferentes. Para evaluar correctamente la red neuronal artificial que se había entrenado, se recolectaron 59 nuevos datos para cada objetos a identificar, obteniendo un porcentaje de acierto para cada objeto del 96.6% y que se encuentra muy aproximado al porcentaje que Matlab encuentra, ver figura 5.




Figura 5. Comparación de la red neuronal (sistema programado autónomo vs Matlab).

Al tener resultados positivos con la red neuronal, se decidió hacer un recorrido marcando cuatro obstáculos los cuales tendrían que ser identificados por el prototipo y graficados en una interfaz gráfica desarrollada en Matlab. Para la lógica del recorrido, se programó un Atmega 2560 con las instrucciones de navegación, usando un controlador PID considerando la dirección a seguir controlada por medio de un giroscopio MPU 6050.



Figura 6. Matrices de confusión de la red neuronal artificial entrenada (prueba 5.7)

Todos los datos leídos por el sistema de visión se enviaron vía Bluetooth al programa de Matlab. Como resultado se obtuvo en el 75% de objetos presentados se logró la identificación por la red neuronal artificial. Ver figura 7.

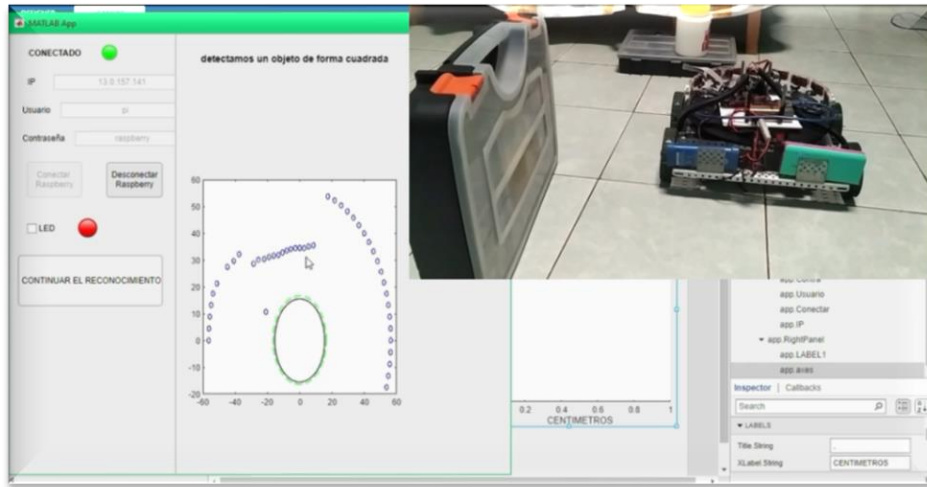


Figura 7. Identificando un objeto cuadrado en Matlab.

Discusión.

Se diseñó y entrenó redes neuronales artificiales para la clasificación de objetos diversos que se le presentaban a un prototipo robótico, el cual mediante una base giratoria y nueve sensores ultrasónicos SFR08 detecta la posición del objeto en un semicírculo de 190° . Se realizaron múltiples pruebas a cada red neuronal entrenada en el sistema de cómputo numérico MATLAB. Con todos los datos recabados y almacenados en formato *.xls se eligió la red neuronal artificial con el mejor porcentaje de acierto y con ello se implementó dicha red en el prototipo robótico. Logrando implementar una red neuronal artificial en la que Matlab le atribuye un porcentaje del 99.8%, sin embargo, mediante pruebas con datos no utilizados en el entrenamiento se logró un porcentaje de acierto real del 96%.

El sistema a pesar de tener un excelente desempeño en la detección de obstáculos y el reconocimiento de patrones, tiene cierto porcentaje de incertidumbre generado por el error que introduce el uso de los sensores ultrasónicos que su método de detección está basado en un volumen frontal cónico que ocasiona estos errores al momento de procesar los vectores de entrada para la red neuronal artificial.

Créditos.

Los autores agradecen al Tecnológico Nacional de México por el financiamiento del proyecto 11162.21-P, de la convocatoria de apoyo a proyectos de desarrollo tecnológico e innovación 2021 y las facilidades del Tecnológico Nacional de México campus Tuxtla Gutiérrez para la realización de este trabajo.

Referencias bibliográficas.

bu-Mostafa, Y. Magdon Ismail, H. Lin. 2012. *Learning from Data: A Short Course*, United States: AMLBook

Burkov, A. 2019. *The Hundred-Page Machine Learning Book*, United States: Recuperado de: <http://themlbook.com/> Julio

García, C. (2017). “Localización activa de robots móviles”. Tesis de licenciatura no publicada. Universidad de la Laguna, Santa cruz de Tenerife, España.

Gonzalo, P. (2019). Aplicación de algoritmos de Machine Learning para la predicción del beneficio por cliente a partir de métricas de google analytics. Tesis de doctorado. Universidad de Valladolid, España.

Nehmzow U. (2003). Introducción. En: Robótica móvil: una introducción práctica. Springer, Londres. https://doi.org/10.1007/978-1-4471-0025-6_1.

The Mathworks (1970-2021). Redes Neuronales . MathWorks.: <https://www.mathworks.com/discovery/neural-network.html>

The Mathworks (1970-2021). Deep Learning . MathWorks.: <https://www.mathworks.com/discovery/deep-learning.html>

Ríos, A. J. (2015). “Reconstrucción de mapas para el recorrido de un vehículo sobre ruedas mediante un dispositivo de cómputo móvil”. Programación Matemática y Software. 7 (2). 41-52. Recuperado de <http://riaa.uaem.mx/xmlui/bitstream/handle/20.500.12055/118/progmat722015Reconstruccion.pdf?sequence=1&isAllowed=y>

Rodríguez, A., & Cortés, J. (2015). “Robot Oruga detector y esquivador de obstáculos con Fuzzy Logic IA”. IV congreso internacional de ingeniería mecánica y automatización: CIIMA 2015. Recuperado a partir de <https://revistas.eia.edu.co/index.php/mem/article/view/849>.

Sandoval L. (2018). Algoritmo de aprendizaje automático para análisis y predicción de datos. Revista tecnológica, vol. 11. 36-40. Recuperado de: http://www.redicces.org.sv/jspui/bitstream/10972/3626/1/Art6_RT2018.pdf

Valencia, J. C. Y., & MESA, M. A. F. (2016). “PMITO-Plataforma móvil para investigación de técnicas de odometría”. Tesis de doctorado no publicado. Universidad Tecnológica de Pereira. Pereira, Colombia.

Información de los autores.



Álvaro Hernández Sol, es Ingeniero en electrónica, egresado del Instituto Tecnológico de Tuxtla Gutiérrez ITTG, en Tuxtla Gutiérrez, Chiapas. Es profesor de tiempo completo en el área de Ingeniería Electrónica del Instituto Tecnológico de Tuxtla Gutiérrez y es investigador desde 1997. Certificado en SolidWorks Associate. Jefe de proyectos de investigación de ingeniería electrónica desde el 2001. Fundó y asesora el “Club de robótica del ITTG”. Colabora en la línea de investigación de “Robótica” de Ingeniería electrónica. Dirige el área de trabajo en “Robótica” y es parte del cuerpo académico “sistemas de control inteligentes”. Ha realizado investigaciones en el área de los sistemas alternativos de comunicación y en sistemas robóticos, Así como en sistemas traductores de lenguaje.



Manuel de Jesús Cancino Escobar es Ingeniero Electrónico egresado del Instituto Tecnológico de Tuxtla Gutiérrez. Durante su etapa académica fue presidente del Club de Robótica “Engineer Bots” del I.T.T.G., siendo parte del equipo de diseño para los concursos del torneo de VEX ROBOTIC temporada 2016-2019. Certificado en SolidWorks Associate. En la actualidad es alumno de tiempo completo de la Maestría en Ciencias de Mecatrónica del Tecnológico Nacional de México Campus Tuxtla Gutiérrez. Se especializa en el desarrollo de aplicaciones y programación en Python y Matlab.




Raúl Moreno Rincón, Ingeniero en Comunicaciones y Electrónica, egresado de la ESIME-IPN, en la ciudad de México, D.F. Maestro en Ciencias en Ingeniería Electrónica egresado del Instituto Tecnológico de Toluca. Maestro en Educación Superior por la Universidad Autónoma de Chiapas. Certificado en SolidWorks Associate. Es profesor de tiempo completo en el área de Ingeniería Electrónica del Instituto Tecnológico de Tuxtla Gutiérrez y Jefe de Proyectos de Docencia de Ingeniería Electrónica. Es investigador desde 1999 y Colabora en la línea de investigación “Robótica” de Ingeniería electrónica y es parte del cuerpo académico en formación “sistemas de control inteligentes”. Ha realizado proyectos como: Sistema de alarma para personas con deficiencia auditiva basado en XBEE, robot de cafetería, araña hexápoda, sistema de control de animatronic, entre otros.



José Ángel Zepeda Hernández, es Ingeniero Industrial en Eléctrica y Maestro en Ciencias en Ingeniería Mecatrónica, egresado del Instituto Tecnológico de Tuxtla Gutiérrez ITTG. Es profesor de tiempo completo en el área de Ingeniería Electrónica del Instituto Tecnológico de Tuxtla Gutiérrez e investigador desde 1999, Imparte cátedra en el área de Ingeniería Electrónica y la Maestría en Ciencias en Ingeniería Mecatrónica en el ITTG, donde imparte las asignaturas de Diseño con Transistores y Electrónica Básica respectivamente. Líder del cuerpo académico en formación “sistemas de control inteligentes”.



Aldo Esteban Aguilar Castillejos, obtuvo el grado de Maestro en Ciencias en Ing. Mecatrónica en el Instituto Tecnológico de Tuxtla Gutiérrez (ITTG) en el 2011 y el título de Ingeniero en Electrónica en el mismo Instituto, con especialidad en Instrumentación y Control. Certificado en SolidWorks Associate y SolidWorks Professional Avanzado, con Diplomado en Competencias para la enseñanza de las ciencias, Diplomado en Unreal Engine. Actualmente es parte del cuerpo académico en formación “sistemas de control inteligentes” del I.T.T.G. y parte del grupo de investigación en la Universidad del Valle de México, con desarrollos de proyectos financiados por CONACyT y empresas privadas. Con campos de interés en: dispositivos opto-mecatrónicos, manufactura, sensores de fibra óptica, instrumentación y control.



Osbaldo Ysaac García Ramos, Maestro en Ciencias en Ingeniería Mecatrónica egresado del Instituto Tecnológico de Tuxtla Gutiérrez. Académico de Tiempo Completo en UVM desde 2005. Tiene 12 años de experiencia docente. Tiene Cursos especialización en Mecatrónica en Universidad de Esslingen Alemania, en la empresa Emco Salzburgo Austria, en la empresa Festo Estados Unidos y Festo México. Responsable técnico del proyecto de investigación “Consolidar un centro de investigación y desarrollo de vehículos eléctricos funcionales y confortables e impulsados por energía limpia” junto con la empresa Invemex S.A de C.V., 2015. Ha desarrollado proyectos de investigación como ‘Sistema de medición de hélices de barco para la secretaria de marina financiado por Conacyt y Semar’, “Diseño y caracterización de Biomateriales a partir de macromicetos como alternativa al uso del unicef” en el año 2014 (financiados por Conacyt). Tiene participaciones en congresos internacionales como congreso Tecno láser Habana Cuba 2013 con artículo y ponencia ‘Método de registro automático de imágenes de rango tridimensionales para restauración de piezas arqueológicas’.