

Sistema de percepción no centralizado para enjambres de robots RAOI basado en aprendizaje profundo

Erik Ricardo Palacios-Garza, Luis Martín Torres-Treviño

Universidad Autónoma de Nuevo León,
Facultad de Ingeniería Mecánica y Eléctrica,
México

{erik.palaciosgrz, luis.torrestrv}@uanl.edu.mx

Resumen. En el área de la robótica, la implementación de sistemas de percepción es de gran importancia. Actualmente, con el desarrollo del aprendizaje profundo, ha sido posible desarrollar sistemas de visión extremadamente complejos. Sin embargo, en la robótica de enjambres, esta tecnología aún no ha sido adaptada a la percepción de cada robot. Con este trabajo se ha implementado un sistema de visión basado en el aprendizaje profundo en un miembro de un enjambre de robots de configuración diferencial. Esta implementación se llevó a cabo en un NVIDIA® Jetson Nano™ 2GB Developer Kit, utilizando la cámara Raspberry Pi. Los resultados fueron el aumento en la cantidad de estímulos que el enjambre puede detectar, lo que permite el desarrollo de más comportamientos de enjambre.

Palabras clave: Robótica de enjambres, deep learning, percepción, visión artificial.

Decentralized Perception System for RAOI Robot Swarms based on Deep Learning

Abstract. In the area of robotics, the implementation of perception systems is of great importance, currently with the development of deep learning it has been possible to develop extremely complex vision systems, however in swarm robotics this technology has not yet been adapted to the perception of each robot, with this work a vision system based on deep learning has been implemented to a member of a swarm of differential configuration robots, this implementation was carried out on a NVIDIA® Jetson Nano™ 2GB Developer Kit, using the raspberry pi camera. The results were the increase in the amount of stimuli that the swarm can detect, allowing the development of more swarm behaviors.

Keywords: Swarm robotics, deep learning, perception, artificial vision.

1. Introducción

Dentro de la robótica se han implementado diversos sistemas de percepción para generar tareas cada vez más complejas en diferentes áreas de la ciencia, en la medicina se aplica en robots quirúrgicos o mecanismos para la realización de diferentes estudios médicos, en la industria se utiliza en robots controladores de calidad, robots ensambladores entre muchos otros, también dentro de la agricultura, con su implementación en robots controladores de plagas, sin embargo, en la robótica de enjambres los sistemas de percepción han sido limitados a sensores sencillos como ultrasónicos, infrarrojos y sensores de iluminación por mencionar algunos, limitando no solo la percepción de cada robot si no también el desarrollo de comportamientos nuevos.

Los sistemas de percepción han pasado por una gran evolución en los últimos años con la implementación de modelos de redes neuronales en el reconocimiento, clasificación y detección de objetos en imágenes, gracias a esto se ha ampliado el campo de aplicaciones con sistemas de visión, ya que anteriormente las técnicas de procesamiento de imágenes estaban limitadas a condiciones del ambiente en el cual se capturaban las imágenes, por lo que la complejidad del diseño de un sistema de percepción para enjambres de robots basado en procesamiento de imágenes se vuelve enorme, una posible adaptación de estas técnicas es la utilización de modelos centralizados, sin embargo dentro de la robótica de enjambres limita la movilidad y la diversidad de aplicaciones que este tipo de arquitecturas pueden realizar.

La robótica de enjambres trata de resolver problemas complejos usando un conjunto de robots de baja complejidad y bajo costo, como por ejemplo exploración, localización, construcción etc.

Una de las ventajas de trabajar con estas configuraciones es que pueden cumplir con la tarea asignada aun con la pérdida o inclusión de miembros nuevos al enjambre, así como disminuir la complejidad de los algoritmos en cada robot, al emerger comportamientos autónomos del enjambre.

En la mayoría de los casos, como se menciona en [8] estos robots son construidos con un cierto nivel de percepción, el cual consiste en un conjunto de sensores que les permiten tener cierta información del espacio que los rodea, los obstáculos que se podrían encontrar, u objetos con los cuales interactuar, por ejemplo los robots utilizados en [8] utilizan sensores de proximidad y luz para medir la distancia con robots vecinos u objetos, además de obtener información con la luz del lugar donde se encuentren, con esta percepción asignada a cada robot se han obtenido resultados sorprendentes como los mencionados en el artículo, sin embargo tiene la limitante de solo obtener información local de medio ambiente proporcionada por estos sensores.

En [11] se menciona una problemática de percepción similar que en [8] donde la comunicación a corta distancia, representa un reto que propicia el desarrollo de algoritmos más complejos para la robótica de enjambres, presentando la percepción asignada a cada robot como restrictiva.

Existen algunos otros sistemas de percepción para robótica de enjambres más complejos, pero que a su vez proporcionan una mayor capacidad de trabajo a cada robot y al sistema completo, como es el caso de [3], donde utilizan gestos de manos para manipular el comportamiento grupal de los robots, este reconocimiento de gestos manuales está basado en un preprocesado de la imagen capturada de la mano, una

extracción de características y un clasificador de SVM's. Claramente agregando un sistema de visión se puede observar que se tienen comportamientos que considerando un sistema por sensores serían complicados de obtener.

En el procesamiento de imágenes existen máscaras prediseñadas para la extracción de ciertas características, pero debido a que muchas veces estas máscaras no son suficientemente especializadas para encontrar las características deseadas se recurre a las redes neuronales convolucionales (CNN) las cuales buscan máscaras óptimas para la extracción de características específicas de una imagen y así poder hacer reconocimiento, clasificación o detección de objetos en imágenes [13], comúnmente las CNN constan de una parte donde se utilizan convoluciones con las máscaras antes mencionadas y esta se conecta a un perceptrón [12] para proporcionar una salida de clasificación, siendo esta configuración una de las más utilizadas.

En trabajos posteriores al antes mencionado, se plantea la idea de usar redes neuronales convolucionales [6], dichas redes tienen la ventaja de tener una alta precisión en la tarea de visión que se les asigne, además de poseer gran robustez a las condiciones ambientales donde se capture la imagen a analizar, en la actualidad existe equipo en donde se pueden embeber y utilizar en sistemas robóticos móviles, la desventaja ahora presente es el poder de cómputo que se necesita para su entrenamiento, donde es necesario tanto un gran número de imágenes como computadoras suficientemente potentes para ejecutar el entrenamiento que requieren.

Regresando a [6] se propone un modelo de CNN donde cambian la red de perceptrón por una SVM, dando como resultado una mejora en la precisión de la CNN. Con esta implementación en un enjambre de robots se podrían abrir una serie de tareas y comportamientos más complejos o mejorar las tareas que ya se realizan en la actualidad.

Sin embargo, si en lugar de implementar una CNN entrenada para detectar gestos realizados con las manos, se entrenan para poder percibir su medio ambiente, se podría dar lugar a comportamientos más eficientes y más complejos que podrá realizar el enjambre sin la necesidad de intervención humana, un ejemplo de estas nuevas alternativas a estos comportamientos es la solución a una problemática planteada en [7] donde se menciona que con sensores sencillos un robot no tiene la posibilidad de conocer la orientación de sus vecinos, con la implementación de una CNN se puede abrir esta capacidad a los robots.

2. Sistema de percepción no centralizado para enjambres de robots RAOI basado en Deep Learning

En este trabajo se presenta un sistema de percepción no centralizado aplicable a enjambres de robots, el cual cumple con la función de detectar diversos estímulos de influencia y objetos de interés dentro de las zonas de trabajo de los enjambres, con el aumento drástico en los estímulos de influencia del enjambre este puede generar nuevos y más complejos comportamientos.

El resto del documento se organiza de la siguiente manera: En la siguiente sección se explican los modelos de Deep learning utilizados para la detección correcta de los estímulos de influencia, así como conceptos básicos de enjambres de robots RAOI.

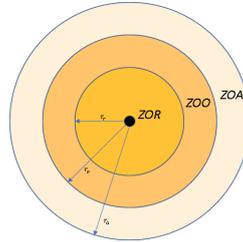


Fig. 1. Zonas de repulsión, orientación y atracción.

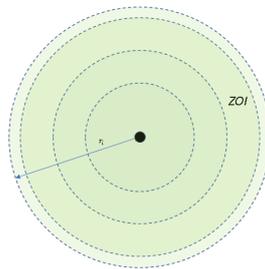


Fig. 2. Zona de influencia.

Luego, se explica el hardware y desarrollo del prototipo robótico de experimentación. Posteriormente, se ilustran los resultados de experimentos de búsqueda de un estímulo de influencia, finalmente se presenta la discusión sobre los resultados, las conclusiones y trabajos futuros.

3. Metodología

En esta sección se explican los elementos teóricos más relevantes para este trabajo, en cuanto al área de robótica de enjambres se mencionan conceptos de áreas RAOI y su generación de comportamientos en enjambres de robots, en seguida se presentan algunos conceptos básicos de las redes de clasificación y detección utilizadas, siendo estas una red residual de 18 capas y una red single shot detector (ssd), finalmente se presenta el comportamiento de experimentación que se utilizó para demostrar la utilidad del sistema de percepción propuesto.

3.1. Enjambres de robots RAOI

El sistema de percepción que se propone, está enfocado para el desarrollo de comportamientos para enjambres de robots RAOI propuestos en Couzin [2], este tipo de comportamientos están basados en características de animales sociales, por ejemplo, abejas, hormigas, lobos, entre otros. Donde se consideran tres características básicas de su movimiento para la generación comportamientos similares a los de ellos.

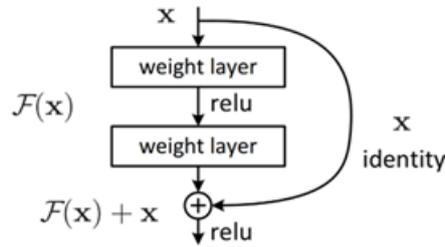


Fig. 3. Modelo básico de un bloque residual [4].

Estas características constan de áreas en las cuales cada animal acostumbra acercarse, alejarse u orientarse, estas fueron nombradas zonas de repulsión, orientación y atracción [10], estas se pueden observar en la figura 1, dentro de la primera zona el individuo trata de alejarse de sus vecinos ya que los considera demasiado cercanos, ya sea para realizar algún movimiento o por una posible colisión, la segunda zona es cuando el individuo considera tener una distancia adecuada de sus vecinos este tratará de orientarse a la misma dirección que ellos, en la última zona si el individuo se encuentra muy distanciado de sus vecinos este tenderá a acercarse a ellos para integrarse al enjambre.

Basándose en estas tres zonas se pueden generar comportamientos similares a los que realizan los animales mencionados anteriormente, sin embargo, en [9] se agregó una nueva zona llamada de influencia la cual se puede apreciar en la figura 2, donde si se tiene la existencia de algún estímulo para el enjambre esta tenderá a realizar la tarea que el estímulo indique, sin embargo debido a las limitaciones que se tienen en los sistemas de percepción de los enjambres propuestos en los trabajos anteriores, el número y tipo de estímulos de influencia se limitaba a las capacidades de los sensores simples que utilizan.

3.2. Redes neuronales convolucionales

Dentro de la visión artificial se trata de cumplir con diferentes objetivos teniendo como principales, el reconocimiento, la clasificación y la detección de objetos, estos objetivos se pueden cumplir con la ayuda de redes neuronales artificiales, las cuales aprenden a extraer características específicas de una imagen para realizar tarea que se desea cumplir, estas redes constan principalmente de los siguientes elementos:

- *Capas convolucionales*: Constan de un mapeo de una matriz de pesos o filtro a lo largo y ancho de una determinada imagen, multiplicando los pesos del filtro por los correspondientes píxeles de la imagen sumando estas multiplicaciones en cada avance dentro del mapeo:

$$C = f(I * K + b), \quad (1)$$

$$C(i, j) = f\left(\sum_{u=0}^{F_i} \sum_{v=0}^{C_o} I(i + u, j + v) \cdot K(u, v) + b\right). \quad (2)$$

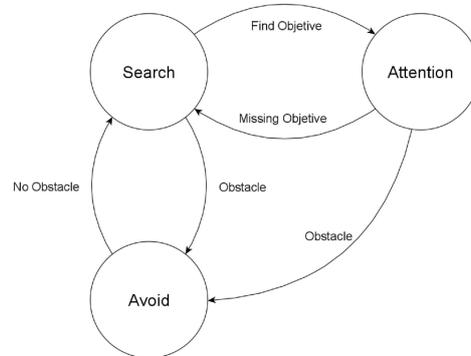


Fig. 4. Comportamiento experimental.

- *Capas de pooling*: Esta etapa redimensiona una determinada imagen para facilitar su procesamiento por capas convolucionales posteriores a esta operación, existen diferentes esquemas de pooling, a continuación, se presenta el más común utilizado, el cual divide la imagen original en grupos de 4 píxeles vecinos, obtiene el promedio de estos cuatro píxeles y los anexa al píxel correspondiente a la vecindad elegida en la imagen original:

$$S(i, j) = \frac{1}{4} \sum_{u=0}^1 \sum_{v=0}^1 C(i + u, j + v). \quad (3)$$

- *Padding*: Consiste en agregar un marco de ceros a la imagen de entrada, sirve para realizar una convolución completa a la imagen.
- *Vectorización*: Este proceso consiste en el redimensionamiento de la última capa convolución a un vector para poder ser procesado por la parte densa de la red:

$$v(k) = C(i, j). \quad (4)$$

Para $i = 0, 1, 2 \dots Fi$, $j = 0, 1, 2 \dots Co$.

3.3. Redes neuronales residuales

Durante el proceso de convolución se tiene una pérdida de información al momento de tratar de incrementar el número de capas para mejorar la eficiencia de la red, esta pérdida de información se puede compensar con la utilización de conexiones residuales, las cuales realizan la integración de información de la entrada de una determinada capa a la salida de otra, permitiendo extender la profundidad de capas sin pérdida de porcentaje en métricas de evaluación, el conjunto de todas las capas que salta la conexión residual se le llama bloque residual y al conjunto de bloques residuales se le conoce como red residual o Resnet, en la figura 3 se puede apreciar un bloque residual.

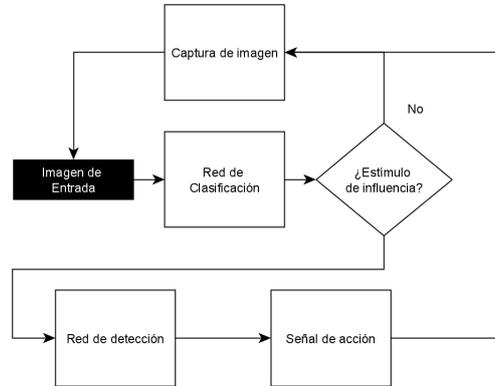


Fig. 5. Esquema de percepción propuesto.

3.4. Redes de detección

La limitación de usar redes de clasificación es que no se puede identificar la posición del objeto en la imagen, posicionar el objeto en la imagen es de gran utilidad para el direccionamiento de los robots, existen diferentes modelos de detección en este caso se utilizara el modelo de SSD (single shot detector) [5].

Esta red se basa en dividir la imagen a analizar en celdas, donde cada celda dará las coordenadas, ancho y largo de una serie de encuadres también llamados “bounding boxes”, los cuales trataran de encerrar el objeto de interés de manera precisa, también cada celda otorga información acerca de la posible existencia de un objeto de interés en la celda y la clase a la cual puede pertenecer el objeto.

3.5. Robots diferenciales

La configuración de robot móvil que se utilizó fue la diferencial, teniendo su modelo matemático basado en A. Bara [1] a continuación:

– Modelo Cinemático:

$$\begin{bmatrix} \dot{x}_c \\ \dot{y}_c \\ \dot{\theta} \end{bmatrix} = \begin{bmatrix} \frac{r}{2} \cos(\theta) - \frac{rd}{2R} \sin(\theta) & \frac{r}{2} \cos(\theta) + \frac{rd}{2R} \sin(\theta) \\ \frac{r}{2} \sin(\theta) + \frac{rd}{2R} \cos(\theta) & \frac{r}{2} \sin(\theta) - \frac{rd}{2R} \cos(\theta) \\ \frac{r}{2R} & -\frac{r}{2R} \end{bmatrix}. \quad (5)$$

– Modelo Dinámico:

$$\mathbf{M} \cdot \dot{v} + H(v) = \mathbf{B} \cdot \tau, \quad (6)$$

donde:

$$\begin{bmatrix} m & 0 \\ 0 & I_p + m \cdot d^2 \end{bmatrix} \begin{bmatrix} \dot{v} \\ \dot{w} \end{bmatrix} + \begin{bmatrix} -m \cdot d \cdot \dot{\theta}^2 \\ m \cdot d \cdot v \cdot \dot{\theta} \end{bmatrix} = \begin{bmatrix} \frac{1}{R} & \frac{1}{r} \\ \frac{1}{r} & -\frac{1}{R} \end{bmatrix} \begin{bmatrix} \tau_{dr} \\ \tau_{dl} \end{bmatrix}. \quad (7)$$

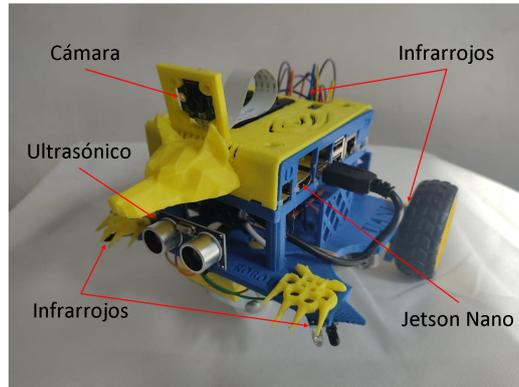


Fig. 6. Prototipo experimental.

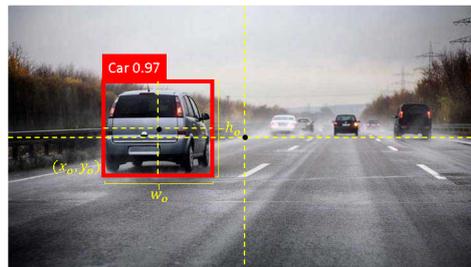


Fig. 7. Obtención de magnitudes.

4. Propuesta de sistema de percepción

4.1. Comportamiento de experimentación

Para poner a prueba el sistema de percepción propuesto en un robot, se utilizó un comportamiento de búsqueda aplicado como una máquina de estados finita ilustrada en la figura 4, compuesta por tres estados, “búsqueda”, “atención” y “evasión”. Donde el estado de búsqueda se encargará de encontrar un estímulo de influencia dentro de la imagen captada por el robot, el estado de atención encuentra la orientación del estímulo de influencia así como una aproximación de cuan alejado esta, por último el estado de evasión se encarga de evitar obstáculos mediante sensores infrarrojos.

4.2. Esquema propuesto de sistema de percepción para enjambres de robots

Teniendo las herramientas del Deep Learning que se mencionaron anteriormente y utilizando los módulos proporcionados por la librería jetson inference, se pueden utilizar en conjunto para poder cumplir con las demandas de percepción que tiene cada robot, por lo que se propone un sistema compuesto por dos redes neuronales, una de clasificación y una red de detección, esto disminuye el coste computacional en

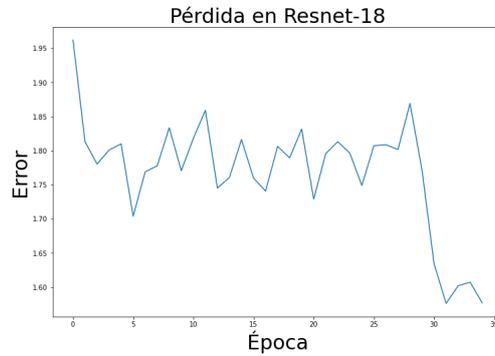


Fig. 8. Evolución del error en la red de clasificación.

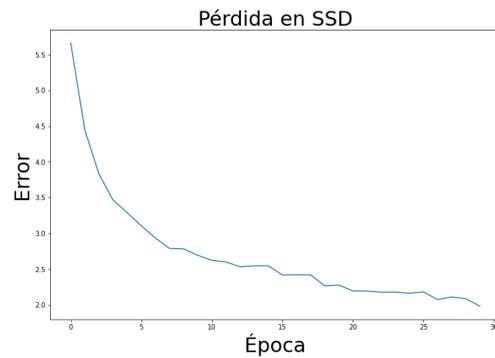


Fig. 9. Evolución del error en la red de detección (épocas 0-50).

la tarjeta utilizada ya que el tiempo de ejecución de la red de detección es muy alto se propone reducir su tiempo activo, por lo que para fines del comportamiento que se desea reproducir en este artículo estará activa la mayor parte del tiempo la red de clasificación y solo en cuanto se detecte una señal de influencia del enjambre se activará la red de detección como se puede observar en la figura 5.

La red de clasificación consiste en una Resnet-18, la cual consta de 8 bloques convolucionales divididos cada uno en dos etapas de convolución con filtros de 3x3, el primer bloque consta de dos etapas de 64 filtros con una imagen de salida de 56x56, a continuación, el segundo bloque con dos etapas de convolución de 128 filtros con una salida de 28x28, el tercero consta de dos etapas de 256 filtros con salida de 14x14 y por último un bloque de 512 filtros con salida de 7x7.

Como ya se mencionó antes se utilizó una red residual de tres bloques como los que se muestran a continuación:

En cuanto a la red de clasificación como ya se mencionó en la sección anterior se utilizará la red SSD, esto por su precisión y velocidad demostradas en la literatura.



Fig. 10. Estímulos de influencia.

4.3. Prototipo experimental Wolfbot

Para poner a prueba el sistema de percepción se sometió a un comportamiento de búsqueda un solo robot como el que se aprecia en la figura 6.

El hardware del robot se describe a continuación:

- *Microcontrolador*: La tarjeta electrónica *Jetson Nano*™ de NVIDIA® la cual contiene el código computacional del controlador de los motores y del sistema de percepción. Las características más importantes para la selección de esta tarjeta son principalmente, la capacidad de trabajo con redes neuronales y procesamiento de imágenes, además de mantener en la medida de lo posible el rasgo minimalista del hardware de los robots.
- *Motores de CD*: El robot tiene dos motores de corriente directa controlados con controladores PD.
- *Sensores infrarrojos*: Se utilizan para evitar posibles obstáculos que se interpongan con el robot.
- *Sensor ultrasónico*: Cumple la función de la detección de los obstáculos quitándole complejidad a las redes neuronales.

Las pruebas de experimentación se realizaron en un ambiente de dimensiones controladas donde se colocaron 3 estímulos de influencia diferentes para la atracción de cada robot.

4.4. Control

Para lograr el control correcto de los motores se utilizaron dos controladores PD, uno controla la orientación del robot y otro controla la distancia entre el estímulo y el robot, los dos funcionan tomando como referencia la información que entrega la SSD acerca de las bounding boxes que encuadran al estímulo, el controlador de la orientación utiliza como señal de retroalimentación el centro de la bounding box y como señal de referencia el centro de la imagen que recibe, para el controlador de distancia se utiliza como señal de retroalimentación el ancho W_0 de la bounding box y como referencia se coloca el valor de repulsión al estímulo que se desee, un ejemplo de visualización de estos datos es el de la figura 7.

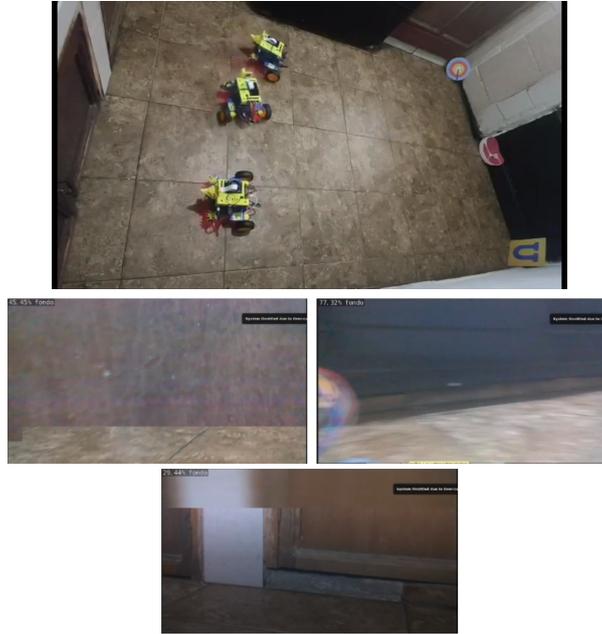


Fig. 11. Muestra de estado de búsqueda.

5. Resultados

5.1. Entrenamiento de red de clasificación

El entrenamiento se realizó con 600 imágenes de 3 diferentes clases: "Vació", "Objetivo", "Ü", "çarne", robot.^a 35 épocas, en las figuras 8 se puede apreciar la evolución del error de la red de clasificación a lo largo del entrenamiento.

5.2. Entrenamiento de red de detección

El entrenamiento se realizó con 600 imágenes de 3 diferentes clases: "Vació", "Objetivo", "Ü", "çarne", robot.^a 30 épocas, en la figura 9 se puede apreciar la evolución del error de la red detección a lo largo del entrenamiento, así como la evolución del error de regresión y clasificación marcados por la función de error de la red SSD [5].

5.3. Experimentación de comportamiento de búsqueda

La experimentación se realizó utilizando tres robots, sin aplicar reglas de comportamientos colectivos se evaluaron individualmente a cada robot, los experimentos se realizaron colocando estímulos de influencia en diferentes posiciones del área de trabajo de los robots. Estos estímulos de influencia se muestran en la figura 10.

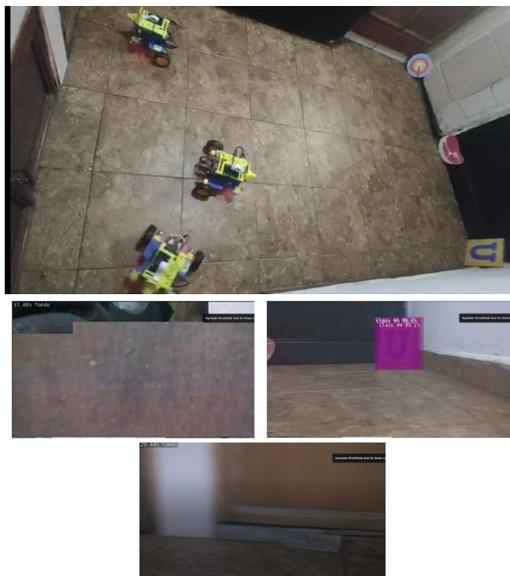


Fig. 12. Muestra de estado de atención.

Estado de búsqueda: En la figura 11 se puede observar el estado de búsqueda de cada robot, donde se encuentra activa la red de reconocimiento la cual se encarga de decir si existe un objeto de interés en la imagen que está observando el robot, como no se aprecia el estímulo de influencia se mantiene en el estado de búsqueda.

Estado de atención: Una vez que se detectado un estímulo de influencia se entra en el estado de atención comenzando a actuar la red de detección como se aprecia en la figura 12 donde se localiza el objeto, se ajusta la orientación del robot hacia el estímulo para a continuación aproximarse hacia él, deteniéndose hasta que se esté por alcanzar la zona de repulsión 13.

Estado de evasión: El estado de evasión no se puede apreciar claramente en las figuras de resultados sin embargo en la figura 12 se puede apreciar como el robot de la parte inferior de la imagen esta por colisionar considerando que el área de trabajo es totalmente cerrada tomando la forma rectangular”que se aprecia en las imágenes, tomando de referencia este robot se puede observar en la figura 13 como ha logrado no colisionar y cumplir con el objetivo de encontrar algún estímulo de influencia.

Se realizaron en total 6 experimentos de los cuales dos fueron considerando un obstáculo en el centro del área de trabajo y un solo estímulo de influencia y dos considerando varios estímulos de influencia, logrando cumplir con el objetivo de aproximarse a un estímulo cada robot.



Fig. 13. Muestra de estado de atención (aproximación).

6. Conclusiones

Los experimentos muestran resultados aceptables cumpliendo con el objetivo del comportamiento de búsqueda, al tener una buena precisión en las redes de clasificación y detección se logra encontrar el estímulo de interés, sin embargo al aumentar el número de estímulos de influencia en la red de clasificación incrementa la dificultad de generalizar el concepto de fondo dentro de la red, es decir lograr que la red de clasificación pueda decir si existe o no un objeto de interés.

La implementación del sistema de visión propuesto mostró que es posible la localización de objetos en tiempo real, utilizando un enfoque descentralizado el cual puede ser utilizado para desarrollar nuevos comportamientos dentro de la robótica de enjambres, dejando de depender de sensores limitados a la medición de magnitudes básicas del entorno del robot, cabe mencionar que estos sensores siguen siendo indispensables para el funcionamiento correcto de un enjambre al contribuir a la detección de señales del medio ambiente del robot que no serían claramente reconocidas por un sistema de visión convencional, como por ejemplo, cambios sutiles en iluminación o sonidos que pudieran ser de utilidad en el desarrollo de comportamientos más complejos, además de poder demostrar que con la implementación de sistemas de visión basados en Deep Learning es posible obtener múltiples estímulos de influencia en el enjambre dando paso al cumplimiento de tareas más diversas por el enjambre, además de notar que la utilización de una o más redes a un sistema de visión de cualquier modalidad, permite mejorar la precisión del sistema de visión, disminuir la carga computacional en su ejecución y disminuir la complejidad del aprendizaje de las redes.

Referencias

1. Bara, A., Dale, S.: Dynamic modeling and stabilization of wheeled mobile robot. In: Proceedings of the 5th WSEAS International Conference on Dynamical Systems and Control (2009)
2. Couzin, I. D., Krause, J., James, R., Ruxton, G. D., Franks, N. R.: Collective memory and spatial sorting in animal groups. *Journal of theoretical biology*, vol. 218, no. 1, pp. 1–11 (2002)
3. Giusti, A., Nagi, J., Gambardella, L., Di Caro, G. A.: Cooperative sensing and recognition by a swarm of mobile robots. In: 2012 IEEE/RSJ International Conference on Intelligent Robots and Systems, pp. 551–558 (2012)
4. He, K., Zhang, X., Ren, S., Sun, J.: Deep residual learning for image recognition. In: Proceedings of the IEEE conference on computer vision and pattern recognition, pp. 770–778 (2016)
5. Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., Berg, A. C.: Ssd: Single shot multibox detector. In: Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part I 14, pp. 21–37 (2016)
6. Nagi, J., Di Caro, G. A., Giusti, A., Nagi, F., Gambardella, L. M.: Convolutional neural support vector machines: Hybrid visual pattern classifiers for multi-robot systems. In: 2012 11th International Conference on Machine Learning and Applications, vol. 1, pp. 27–32 (2012)
7. Ordaz-Rivas, E., Rodríguez-Liñan, A., Aguilera-Ruíz, M., Torres-Treviño, L.: Collective tasks for a flock of robots using influence factor. *Journal of Intelligent & Robotic Systems*, vol. 94, pp. 439–453 (2019)
8. Ordaz-Rivas, E., Rodríguez-Linan, A., Torres-Treviño, L. M.: Collective behaviors in swarms of builder robots. *Research in Computing Science*, vol. 148, no. 11, pp. 103–114 (2019)
9. Ordaz-Rivas, E. D. J.: Colaboración emergente en enjambres de robots, con reglas inspiradas en el comportamiento de animales sociales. Ph.D. thesis, Universidad Autónoma de Nuevo León (2020)
10. Reynolds, C. W.: Flocks, herds and schools: A distributed behavioral model. In: Proceedings of the 14th annual conference on Computer graphics and interactive techniques, pp. 25–34 (1987)
11. Schmickl, T., Möslinger, C., Crailsheim, K.: Collective perception in a robot swarm. In: Swarm Robotics: Second International Workshop, SAB 2006, pp. 144–157 (2007)
12. Zhang, Z.: Derivation of backpropagation in convolutional neural network (cnn). *University of Tennessee, Knoxville, TN*, vol. 22, pp. 23 (2016)
13. Zhao, Z. Q., Zheng, P., Xu, S. T., Wu, X.: Object detection with deep learning: A review. *IEEE transactions on neural networks and learning systems*, vol. 30, no. 11, pp. 3212–3232 (2019)