

# Vehículo solar autónomo de arquitectura electrónica abierta para el desarrollo de algoritmos de gestión de energía

Antonio Guerrero González<sup>1</sup>, Francisco García Córdoba<sup>2</sup>, Inocencio González Reolid<sup>3</sup>

**Resumen**—Este trabajo consiste en la descripción del SAV-UPCT y las posibilidades que nos permite realizar, siendo una plataforma solar autónoma potente para el aprendizaje del comportamiento de un vehículo autónomo, utilizando como fuente de energía la energía solar, que es capturada mediante módulos fotovoltaicos.

Lleva un computador embebido, en el que se ha implementado una red neuronal para el control de la navegación junto con la gestión de la energía, completando un equipo destinado a exploraciones o misiones de larga duración, sin la presencia humana, capaz de reaccionar por sí mismo, ante eventualidades como detección de obstáculos, poca radiación solar, etc.

Permite capturar información mediante sensores y enviar datos en tiempo real a un centro de control.

**Palabras clave**—Plataforma solar, robot navegadores, robot autónomos, vehículos solares autónomos, computación embebida.

## I. INTRODUCCIÓN

**M**EDIANTE unos sensores que captan la información procedente de la tierra, del Sol, de las estrellas y un reloj biológico interno, el cerebro de los animales migratorios construye mapas cognitivos que guían el desplazamiento estacional [1].

Las tortugas bobas (*Caretta caretta*) pueden hacer viajes transoceánicos navegando longitudinalmente o en dirección de este a oeste, sin puntos de referencia visual. Lo hacen mediante señales magnéticas [2].

Al parecer consiguen navegar gracias a que nunca pierden de vista la inclinación e intensidad del campo magnético terrestre, ver Fig. 1, en forma de una “firma magnética”, creando un mapa magnético en sus cerebros con “bi-coordenadas”, de esta manera, consiguen navegar de este a oeste, de norte a sur y viceversa, a lo largo de sus vías migratorias [3], [4], [5], [6].




Fig. 1. Inclinación e intensidad del campo magnético terrestre.

La paloma mensajera utiliza un sistema de navegación similar al de la tortuga boba, cuando no hay sol, ya que disponen de una especie de brújula solar, que detectan la posición exacta del sol en todo momento.

La navegación autónoma de robots en entornos desconocidos constituye uno de los retos tecnológicos más importantes en el campo de la robótica móvil. El problema que se plantea es cuando un robot móvil se encuentra en un ambiente, donde existen una serie de obstáculos y una meta [7].

Se trata de que el robot, por sus propios medios, de forma autónoma, navegue por el entorno, evitando los obstáculos y alcanzando la meta. Hay varios enfoques para resolver el problema, se está trabajando en mejorar los métodos clásicos de planificación de trayectorias, como los grafos de visibilidad, los diagramas de Voroni, etc. [8], los sistemas de control inteligentes basados en técnicas de Inteligencia Artificial, Lógica Fuzzy [9], [10], y las Redes Neuronales Artificiales [11], [12], muchos de estos sistemas están teniendo éxito debido a su gran capacidad de emular los sistemas de navegación natural de los humanos y de los animales.

Se realiza un entorno de simulación mediante Matlab®.

Hay diferentes plataformas robóticas y proyectos destinados a desarrollar la navegación autónoma y la aplicación de energía solar fotovoltaica, a continuación, se exponen varios de ellos [13]-[18].

The Cool Robot es un vehículo autónomo destinado a navegar en ambientes helados, como la Antártida y Groenlandia, para apoyo a investigaciones científicas.

La Microtransat Challenge es una competición trasatlántica de embarcaciones marinas totalmente autónomas. Esta carrera pretende estimular el desarrollo de embarcaciones marinas autónomas a través de una competición.

El SAUV II [13] es un vehículo submarino autónomo propulsado mediante energía solar capaz de operar a profundidades de hasta 500 mts.

## II. DESCRIPCIÓN DE LA PLATAFORMA EXPERIMENTAL

### A. Descripción del SAV-UPCT

En la Fig. 2, se aprecia el robot experimental autónomo SAV, se puede ver en la parte superior la estructura con los módulos solares fotovoltaicos.

\* Corresponding author:

antonio.guerrero@upct.es (Antonio Guerrero González)

Published online at <http://journal.sapub.org/xxx>

Copyright © year Scientific & Academic Publishing. All Rights Reserved




Fig. 2. Vehículo Autónomo Solar, SAV-UPCT

La plataforma experimental lleva también baterías de gel, regulador de carga de baterías y protecciones.

A continuación se realiza una explicación de cada uno de dichos componentes.

Lleva 2 módulos fotovoltaicos de silicio policristalino de elevado rendimiento, con una potencia de 100 Wp cada uno, estos módulos se utilizan para capturar la radiación solar y convertirla en energía eléctrica. El SAV utiliza el regulador de carga FLEmax y su función es la de prevenir la sobrecarga y descarga de las baterías y proteger a los módulos solares cuando no haya radiación solar. También cuenta con 4 baterías o acumuladores utilizados para almacenar la energía de los módulos fotovoltaicos, y proporcionar energía en los momentos de baja radiación.

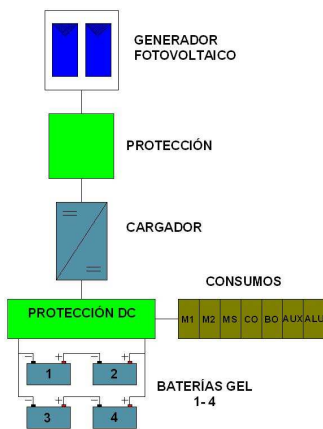


Fig. 3. Esquema instalación energética.

En la Fig. 3, se aprecia el esquema del sistema energético, compuesto por los módulos solares fotovoltaicos, que convierten la radiación solar incidente en energía eléctrica, después de pasar por unas protecciones de DC, la energía se inyecta a las baterías a través de un regulador de carga con control MPP. El sistema trabaja a 24 V.

En la Fig. 4, aparece el esquema del sistema de control embebido, compuesto por una unidad central de procesamiento de datos CPU, sobre la cual se implementa el sistema de red neuronal artificial.

A esta CPU van conectados los diferentes sensores necesarios para la navegación como el s3onar, el laser, comp3as y receptor GPS, por otro lado, se conectan otros

sensores necesarios para verificar el comportamiento del robot como su inclinaci3on, giro y radiaci3on solar incidente sobre los m3odulos solares.

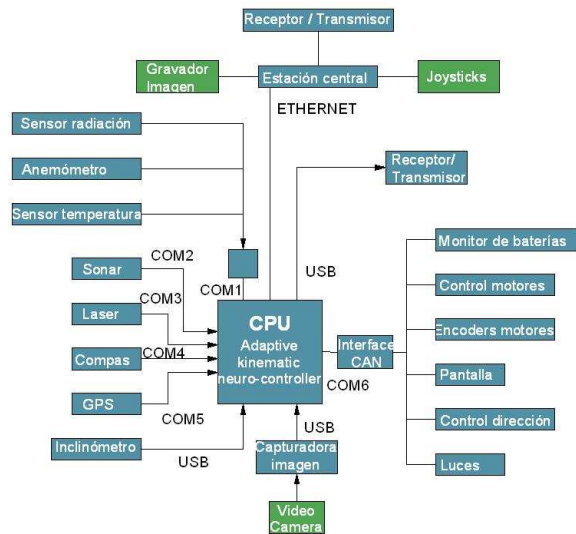


Fig. 4. Interconexiones de elementos del hardware del sistema de control del SAV-UPCT.

Como salidas de actuaci3on se conectan los controladores de los motores de tracci3on, control del sistema energ3tico, pantalla de visualizaci3on de datos, luces de alumbrado y se3alizacion, emisor/receptor de datos para control desde una central, emisor de se3ales de video.

### B. Sistema de Control Energ3tico del Vehículo Autónomo

El sistema de computador empotrado utilizado se puede ver en la foto de la Fig. 5, donde se aprecia a la izquierda la CPU, con las conexiones CAN, RS232, USB, etc., las conexiones COM van por detr3as, a la izquierda est3 el sistema de control y etapas de potencia de los motores que impulsan al SAV, abajo se encuentra el tren de tracci3on con los motores y encoders unidos a los ejes de los motores.




Fig. 5. Computador Empotrado y Sistema de Control Energ3tico del Vehículo Solar.

El SAV lleva un global positioning system (GPS) montado sobre el veh3culo, se utiliza para la navegaci3on aut3noma, que permite conocer la posici3on inicial e introduciendo las coordenadas de la meta, permite al SAV navegar hasta el objetivo, evitando los obst3culos, modificando su trayectoria lo necesario, para evitar la

colisión, para ello, lleva unos sensores sonar perimetrales y un sensor laser de barrido central de 180°, Fig. 6.




Fig. 6. Equipos del sistema energético y laser.

### III. NAVEGACIÓN AUTÓNOMA CON EVASIÓN DE OBSTÁCULOS DE TIPO ON, ARQUITECTURA DE RED NEUROBIOLÓGICA

En las Fig. 7 y Fig. 8, ilustran la arquitectura neuronal propuesta.

Se propone una arquitectura neuronal para robots móviles no-holónicos en entornos no estacionarios, que hace posible la integración de un neurocontrolador cinemático para el seguimiento de trayectorias y un neurocontrolador adaptativo para la evasión de obstáculos.

El neurocontrolador es una red neuronal no-supervisada que aprende a controlar un robot móvil en un entorno no estacionario, la cual se denomina Red Autoorganizativa de mapeado de direcciones (Self-Organization Direction Mapping Network (SODMN), y combina aprendizaje asociativo y mapas asociativos vectoriales (VAM) aprendiendo a generar transformaciones entre coordenadas espaciales y velocidad en motores.

El neurocontrolador adaptativo para la evasión de obstáculos es una red neuronal que aprende a controlar los comportamientos de evasión de obstáculos sobre robots móviles de la forma que los animales aprenden y es conocido como condicionamiento operante.

El aprendizaje, que no requiere supervisión, tiene lugar cuando el robot se mueve alrededor de un ambiente lleno de obstáculos. La red neuronal no requiere el conocimiento de la geometría del robot o de la calidad, el número, o la configuración de los sensores del robot.




Fig. 7. Arquitectura neuronal para la navegación reactiva y adaptativa de un SAV.

#### A. Red SODMN (Self-Organization Direction Mapping Network (SODMN))

La Red SODMN (Self-Organization Direction Mapping Network) expresa las transformaciones de direcciones espaciales a direcciones motoras como un mapeado lineal tal y como se expresa en Fig. 8. El error espacial se calcula para obtener el vector DV (Direction Vector) de dirección espacial. El DV se transforma mediante un mapeado de los elementos  $DV_{ik}$  al correspondiente vector (DVm). Por otro lado, un conjunto de celdas activas inhibitorias, reciben las entradas y determinan el contexto de una acción motor, este conjunto de celdas se denominan campo de contexto. El campo de contexto selecciona los elementos  $V_{ik}$  basado en la configuración inicial de la velocidad angular de las ruedas.




Fig. 8. Red Neuronal para el Auto-Control de la Dirección para el Seguimiento de la Trayectoria del robot SAV.

La señal GO actúa como una puerta multiplicativa no específica y controla el movimiento en todo el campo de velocidades. La señal GO es una entrada que procede del centro de decisión del cerebro, y que varía desde cero antes del movimiento y luego crece suavemente hasta un valor positivo cuando tiene lugar el movimiento. Durante la fase de aprendizaje, la señal GO está inactiva.

Las celdas activas del DVs y DVm están representadas en la red neuronal mediante las cantidades  $(S_1, S_2, \dots, S_m)$  y  $(R_1, R_2, \dots, R_n)$ , respectivamente. El mapeado de direcciones está formado por el campo de celdas con actividades  $V_{ik}$ .

Las actividades de las celdas de DVs y DVm se representan en la red neuronal por las cantidades  $(S_1, S_2, \dots, S_m)$  y  $(R_1, R_2, \dots, R_n)$ , respectivamente [23]-[27]. El mapeado de direcciones se obtiene con un campo de celdas de actividad  $V_{ik}$ . Cada celda  $V_{ik}$  recibe el conjunto completo de las entradas especiales  $S_j, j = 1, m$ , pero conectadas solamente a una celda  $R_i$ . El mapeado de celdas de dirección ( $\mathbf{V} \in \mathfrak{R}^{n \times k}$ ) calcula la diferencia de actividad entre los vectores de dirección motor y espacial a través de la dirección DVm. Durante el

aprendizaje, estas diferencias activan el reajuste de los pesos. Durante la fase de funcionamiento, estas diferencias producen las actividades DVM sobre los valores codificados en el mapeado aprendido.

### B. Red Neuronal NNAB para la evasión de obstáculos (NNAB)

Grossberg propuso un modelo de condicionamiento clásico y operante, el cual se diseñó para tener en cuenta una variedad de datos de comportamiento en el aprendizaje en vertebrados [28]-[35]. Nuestra implementación está basada en el circuito de condicionamiento de Grossberg, el cual sigue la forma muy apropiada al propuesto en Grossberg & Levine [35], [36] and Chang & Gaudiano [37], tal y como se muestra en la Fig. 9.




Fig. 9. Red Neuronal para la Conducta de Evitación de Obstáculos.

En este modelo las señales sensoriales (ambas CS y UCS) se almacenan en una memoria de corto plazo (STM) dentro de las poblaciones designadas como S, las cuales incluyen interacciones competitivas para asegurar que las señales más importantes son contrastadas, mejoradas y almacenadas en el (STM) mientras que las señales menos importantes son suprimidas. Las poblaciones S se modelan como un campo competitivo recurrente en la versión simplificada de tiempo discreto, la cual elimina el ruido inherente, normalizada eficientemente y mejorada por contrastación con las activaciones de los sensores. En el presente modelo, los nodos CS corresponden a la activación desde los sensores de ultrasonidos del robot. En la red  $I_i$  representa un valor del sensor el cual codifica la distancia de objetos próximos con grandes valores y con objetos distantes los valores son pequeños. La red no requiere conocimiento de la geometría del robot móvil o la cantidad, número o distribución de los sensores alrededor del cuerpo del robot.

## IV. RESULTADOS EXPERIMENTALES

### A. Generando trayectorias de entrenamiento

Se hicieron pruebas para verificar la correcta navegación del SAV y el comportamiento de la red neuronal artificial y el ambiente donde navega, se escogieron dos entornos: uno interior, Fig. 10 y uno exterior, Fig. 11. En el interior del ambiente se traza la trayectoria a seguir por el SAV y se colocan unos

obstáculos que el SAV tendrá que evitar, además debe haber radiación solar incidente sobre los módulos solares, para que el robot disponga de fuente de energía.

Las variables de interés para el control del SAV son las coordenadas (x,y) y el ángulo phi que representan la posición y la orientación respectivamente dentro del entorno.

Por otro lado, debemos saber las coordenadas iniciales ( $x_i, y_i$ ) de la ruta, las coordenadas finales ( $x_f, y_f$ ) y las coordenadas de la trayectoria que debe seguir.

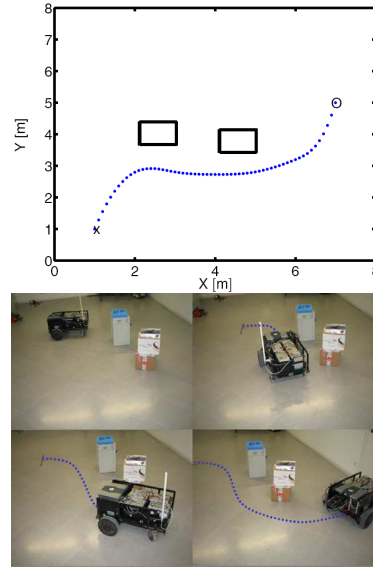


Fig. 10. Prueba del SAV, evitando obstáculos. Control adaptativo de la red SODMN. a) Comportamiento deseado. El símbolo X indica el inicio del movimiento del SAV y  $T_i$  indica los puntos de la trayectoria seguida. b) Control de seguimiento de una trayectoria deseada. c) Seguimiento en tiempo real.

El SAV lleva un sensor de radiación, piranómetro [38] o célula fotovoltaica calibrada, sensores de nivel de carga de los acumuladores y sensores de consumo de energía, para el sistema de gestión de la energía y un sistema de posicionamiento global GPS [39], que una vez introducidas las coordenadas iniciales, finales y la ruta a seguir, permite que éste inicie la ruta, con la mayor precisión posible, a la vez que debe tener en cuenta la energía disponible en sus sistemas de acumulación, para ello, debe en todo momento verificar la radiación incidente, la energía acumulada y el consumo.

En el caso de que haya poca radiación, el SAV debe reducir el consumo de sus sistemas, para ello reduce la velocidad de navegación, en el caso de que baje demasiado la energía de los acumuladores, el sistema de control puede parar el robot y comunicar su estado y localización, por vía remota, a la estación base.



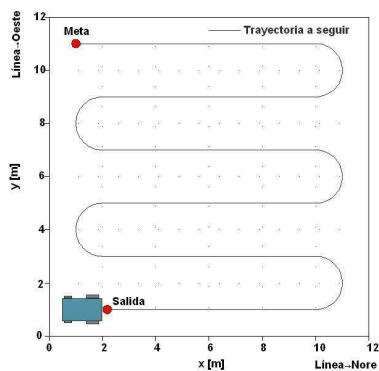


Fig. 11. Trayectoria del robot SAV.

### B. Evitando obstáculos

Una de las características más importantes de las Redes Neuronales Artificiales, es que aprenden a partir de ejemplos. Se debe recopilar una gran cantidad de datos, para poder realizar el proceso de entrenamiento, para la tarea de poder realizar las trayectorias para la que ha sido creada.

Dentro del entorno de la simulación se ha trazado la ruta a seguir y se ha colocado un obstáculo móvil, que puede ser otro robot o vehículo que se cruza en su trayectoria, que se desplaza con una velocidad y dirección concreta.

Tal como se muestra en la Fig. 12, el SAV, mediante sus sensores de obstáculos, detectan al robot o vehículo obstáculo, con suficiente antelación, calcula su dirección, sentido y velocidad, entonces el sistema de control procede a cambiar su rumbo para evadir el obstáculo y después vuelve a su ruta trazada, para continuar con la misión de exploración trazada, tal como aparece en la Fig. 12, en líneas de trazos.

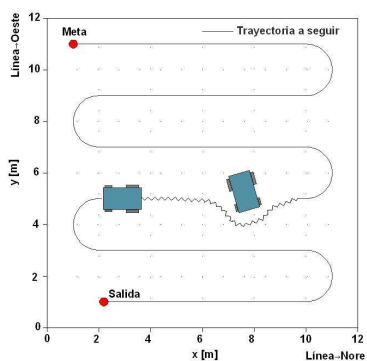


Fig. 12. Trayectoria seguida por el SAV en presencia de un obstáculo.

En la Fig. 13, se ha simulado la trayectoria y una ruta para el SAV, pero se han colocado dos objetos móviles, que pueden ser dos robot o vehículos que se cruzan en su trayectoria, durante la simulación el SAV procedía a evitar los obstáculos, cada vez con más precisión, conforme el sistema de Red Neuronal Artificial va aprendiendo.

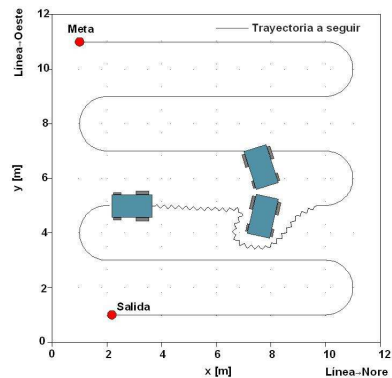


Fig. 13. Trayectoria seguida por el SAV en presencia de varios obstáculos.

### V. CONCLUSIONES

Los puntos más importantes del trabajo son:

Creación de una librería de datos de entrenamiento en Matlab, muy importantes para el aprendizaje de la red.

Se entrenaron varios tipos de Redes Neuronales Artificiales, se compararon los resultados entre ellas, para ver cuál de ellas es más adecuada para este modo de navegación, se utilizó el entorno de Matlab.

Se simularon varias trayectorias y se colocaron varios obstáculos en movimiento, el SAV, en todos los casos, evitó a los obstáculos y volvió a su ruta preestablecida, con más o menos precisión.

Se comprobó que pueden convivir sensores diversos para la detección de obstáculos, sonar y laser, sensores de radiación y consumo energético para la gestión energética y GPS para el seguimiento de la ruta preestablecida.

Se verificó que la red era capaz de generalizar, permitiendo simular trayectorias diferentes, con diferente tamaño y orientación.

Se simuló con diferentes obstáculos, variando su tamaño, su velocidad, dirección y sentido, comprobando que con objetos pequeños, es más difícil su detección y a cierta distancia es complicado averiguar su velocidad, se deben ajustar muy bien todos los sensores, incluso duplicar el sistema de detección de obstáculos, utilizando sensores de diferente tecnología.

El SAV-UPCT es capaz de seguir una ruta sin ayuda humana, al tiempo que toma muestras o recoge datos que sirven para investigaciones científicas, sistemas de guiado autónomo, etc.

### VI. REFERENCIAS

- [1] M<sup>a</sup>. L. Fanjul de Moles and Aldi de Oyarzábal, "Navegación animal". Investigación y Ciencia, diciembre de 2007.
- [2] Nathan F. Putman, Courtney S. Endres, Catherine M. F. Lohmann and K. J. Lohmann, "Longitud Perception and Biordinate Magnetic Maps in Sea Turtles". Current Biology 21, 463-466, March 22, 2011.
- [3] Lohmann, K. J. & Lohmann, "Detection of magnetic inclination angle by sea turtles: a possible mechanism for

- determining latitude". *Journal of Experimental Biology* 194: 23-32. C. M. F. 1994.
- [4] Lohmann, K. J. & Lohmann, "Detection of magnetic field intensity by sea turtles". *Nature*, 380: 59-61. C. M. F. 1996.
- [5] Lohmann K. J., Hester, J. T. & Lohmann, "Long-distance navigation in sea turtles". *Ethology Ecology & Evolution*, 11: 1-23. C. M. F. 1999.
- [6] Lohmann, K. J., Cain, S. D., Dodge, S. A. & Lohmann, "Regional magnetic fields as navigational markers for sea turtles". *Science*, 294: 364-366. C. M. F. 2001.
- [7] M<sup>a</sup> C. Marcos provecho, R. Guzmán Martínez y R. Alaíz Rodríguez, "Autoguiado de robots móviles mediante redes neuronales". Escuela de Ingenierías Industrial e Informática, Dpto. Ingeniería Eléctrica y Electrónica. Universidad de León. XXV Jornadas de Automática, Ciudad Real, del 8 al 10 de septiembre de 2004.
- [8] A. Ollero Baturone, "Robótica Manipuladores y robots móviles", Ed. Marcombo. ISBN: 84-481-0815-9. 2001.
- [9] R. Brooks, "A Robust Layered Control System for a Mobile Robot". *IEEE Journal on Robotics and Automation*, Vol. RA-2, N<sup>o</sup>1, pp 14-23.
- [10] N. Nilsson, "Inteligencia Artificial: una nueva síntesis". Ed. McGraw-Hill. ISBN 84-481-2824-9. España 2001.
- [11] R. J. Mitchell and D. A. Keating, "Neural Network Control of Simple Mobile Robot". Department of Cybernetics. The University of Reading. Reading, UK.
- [12] Yan Zhou, D. Wilkins and Robert Cook, "Neural Network Control for A Fire-Fighting Robot". University of Mississippi. Dept. of Computer and Information Science.
- [13] "Solar Powered Autonomous Underwater Vehicle, FSI SAUV II". Falmouth Scientific, Inc. 1400 Route 28<sup>a</sup>, <box 315, Cataumet, MA 02534-0315, septiembre 2004, 2008 and 2009.
- [14] <http://www.microtransat.org/index.php?lang=en>
- [15] P. Forde Rynne. "Design & performance of wind and solar-powered autonomous surface vehicle". Thesis for the Degree of Master of Science. Florida Atlantic University. December 2008.
- [16] A. Lammas, K. Sammut, F. He. "6-DoF Navigation Systems for Autonomous Underwater Vehicles". Flinders University Australia.
- [17] R. McEwen, H. Thomas, D. Weber, F. Psota. "Performance of an AUV Navigation System at Arctic Latitudes". Monterrey Bay Aquarium Research Institute, Kearfott Guidance and Navigation Corporation. October of 2001.
- [18] L. E. Ray, J. H. Lever, A. D. Streeter. "Performance of a Solar-Powered Robot for Polar Instrument Networks". Thayer School of Engineering, Dartmouth College Hanover, Cold Regions Research and Engineering Laboratory U.S. Army ERDC, Hanover.
- [19] <http://www.aber.ac.uk/en/cs/news-archive/2010/title-97105-en.html>.
- [20] <http://liquidr.com/>.
- [21] <http://www.planetsolar.org/>.
- [22] Li, Z.X., Bui, T.D.: Robot path planning using fluid model. *J. Intell. Robot. Syst.*, 21 (1998) 29-50.
- [23] Ritter, H.J., Martinez, T.M., Schulten, K.J.: Topology-conserving maps for learning visuo-motor coordination. *Neural Networks* 2 (1989) 159-168.
- [24] García-Córdova, F.: A cortical network for control of voluntary movements in a robot finger. *Neurocomputing* 71 (2007) 374-391.
- [25] García-Córdova, F., Guerrero-González, A., Marín-García, F.: Design and implementation of an adaptive neuro-controller for trajectory tracking of nonholonomic wheeled mobile robots. In Mira, J., Álvarez, J.R., eds.: *Nature Inspired Problem-Solving Methods in Knowledge Engineering, Lectures Notes in Computer Science*. Volume 4528. Springer-Verlag Berlin Heidelberg, LNCS- 4528, Part II, ISBN: 978-3-540-73054-5 (2007) 459-468.
- [26] Gaudiano, P., Grossberg, S.: Vector associative maps: Unsupervised real-time error-based learning and control of movement trajectories. *Neural Networks* 4 (1991) 147-183.
- [27] Baraduc, P., Guigon, E., Burnod, Y.: Recording arm position to learn visuomotor transformations. *Cerebral Cortex* 11 (2001) 906-917.
- [28] Georgopoulos, A.P.: Neural coding of the direction of reaching and a comparison with saccadic eye movements. *Cold Spring Harbor Symposia in Quantitative Biology* 55 (1990) 849-859.
- [29] Caminiti, R., Johnson, P., Urbano, A.: Making arm movements within different parts of space: Dynamic aspects in the primate motor cortex. *Journal of Neuroscience* 10 (1990) 2039-2058.
- [30] Rondot, P., De-Recondo, J., Dumas, J.: Visuomotor ataxia. *Brain* 100 (1976), 355-376.
- [31] Lacquaniti, F., Guigon, E., Bianchi, L., Ferraina, S., Caminiti, R.: Representing spatial information for limb movement: Role of area 5 in the monkey. *Cerebral Cortex* 5 (1995) 391-409.
- [32] Fiala, J.C.: *Neural Network Models of Motor Timing and Coordination*. PhD thesis, Boston University (1996).
- [33] Fujii, T., Arai, Y., Asama, H., Endo, I.: Multilayered reinforcement learning for complicated collision avoidance problems. In: *Proceedings IEEE International Conference on Robotics and Automation*. Volume 3, Leuven, Belgium (1998) 2186-2191.
- [34] Carreras, M., Yuh, J., Battle, J., Ridao, P.: A behavior-based scheme using reinforcement learning for autonomous underwater vehicles. *IEEE JOURNAL OF OCEANIC ENGINEERING* 30 (2005) 416-427.
- [35] Grossberg, S.: On the dynamics of operant conditioning. *Journal of Theoretical Biology* 33 (1971) 225—255
- [36] Grossberg, S., Levine, D.: Neural dynamics of attentionally modulated Pavlovian conditioning: Blocking, interstimulus interval, and secondary reinforcement. *Applied Optics* 26 (1987), 5015—5030.
- [37] Chang, C., Gaudiano, P.: Application of biological learning theories to mobile robot avoidance and approach behaviors. *J. Complex Systems* 1 (1998) 79—114.
- [38] J. M. Andújar Márquez. "Aportaciones a la instrumentación electrónica en la optimización de sistemas basados en energía solar". Tesis doctoral. Universidad de Huelva. 16 de diciembre de 2009.
- [39] J. R. Rey. "El sistema de posicionamiento global-GPS". University of Florida. IFAS Extensión.