

DETECCION DE OBJETOS COMPLEJOS USANDO REDES NEURALES Y MICRO TEMBLOR OCULAR

OSCAR GUILLERMO CHANG TORTOLERO

Escuela de Ingeniería Eléctrica. Universidad Central de Venezuela. e-mail:ogchang@gmail.com

Recibido: febrero 2013

Recibido en forma final revisado: octubre 2013

RESUMEN

Presentamos un sistema reconecedor-seguidor en el cual dos redes neurales conectadas en cascada, entrenadas independientemente y con diferentes criterios, colaboran para procesar imágenes y producir el reconocimiento confiable de un objeto que se mueve libremente en el mundo real y que se visualiza a través de una webcam. El uso de redes neurales es importante porque funcionan mediante ejemplos y el usuario no necesita conocer los fenómenos subyacentes, también permiten ejecutar procesamiento paralelo. La primera red se especializa en seguir un objeto seleccionado y una vez entrenada participa en un sistema de control a lazo cerrado en el cual las imágenes recibidas controlan directamente el movimiento del ojo. Este arreglo reproduce artificialmente un fenómeno similar al micro temblor ocular (OMT, por sus siglas en inglés) característico en los ojos de los mamíferos. Las señales OMT son guardadas en elementos de memoria de corta duración y se convierten en la entrada de una segunda red neural que converge en una única “célula concepto”, cuya actividad determina la presencia del objeto seleccionado. El método ha sido probado exitosamente usando imágenes reales en tiempo real y bajo condiciones visuales difíciles que incluyen fondo complejo, objetos complejos y variaciones en escala, inclinación y perspectiva. El sistema de visión artificial propuesto podría usarse en actividades sociales importantes tales como: medicina, agricultura, medio ambiente, construcción, seguridad, militar, entre otros.

Palabras clave: Visión robótica, Redes neurales, Reconocimiento de patrones complejos, Micro temblor ocular, Célula concepto.

DETECTION OF COMPLEX OBJECTS BY USING NEURAL NETWORKS AND OCULAR MICROTREMOR

ABSTRACT

We present a tracking-recognition system in which two cascaded, independently trained neural networks, cooperate in order to process images and produce the real time reliable recognition of an object that moves in the real world and is visualized through a web cam. The first net specializes in tracking one specific object and once trained it participates in a closed loop control system in which received images directly control eye movements. This arrangement artificially reproduces a phenomenon similar to the ocular micro tremor (OMT) characteristic in mammals' eyes. The micro tremor signals are stored in short term memory elements and become the input to a second net which converges into a single “concept cell”, whose activity determines the presence of the selected object. The method has been tested using real time real world images under rough visual conditions which include complex background, complex objects and variations in scaling, tilt and perspective. Thanks to its acute artificial vision, our proposed system could be used in relevant social activities such as: Medicine (automatic recognition of tumors and fractures, help to vision impaired people), Agriculture (crop health), Ecology (fire detection and unusual environment behavior), construction (building progress measurement), security (intruder detection), military (moving target tracking and detection), among others.

Keywords: Robotic vision, Neural nets, Complex pattern recognition, Ocular micro tremor, Concept cell.

INTRODUCCION

La detección y reconocimiento de patrones complejos mediante órganos captadores de imágenes (ojos) es una de las columnas fundamentales en la evolución de formas de vida inteligentes (Moravec, 1984). Podemos mencionar como ejemplo que en todas las formas de existencia conocida los primeros lugares en cuanto inteligencia relativa -en sus respectivos reinos- lo tienen individuos con un acucioso sentido de la vista (humanos, pulpos, abejas, libélulas, entre otros.). En otras ramas de la biología y la neurociencia también han sido detectadas estrechas relaciones entre inteligencia y visión (SeanSeang-M., 2004), (S. Saw, 2004). Finalmente existen reconocidas referencias en el mundo de la robótica y la visión artificial que destacan la vinculación entre visión e inteligencia. (Brooks, 1991).

En el mundo biológico movimiento y reconocimiento están íntimamente ligados. En el ojo de la rana, por ejemplo, los objetos que se quedan quietos desaparecen de la percepción del batracio. De hecho, antes de que el animal pueda reconocer a un objeto como predador o comida y seleccionar un comportamiento apropiado y vital, tal objeto tiene que moverse y crear una imagen móvil dentro del sistema visual de la rana (Olmsted, 2006). Los mamíferos han resuelto esta limitación usando un mecanismo más radical: Micro Temblor Ocular (OMT por sus siglas en inglés). En esta forma de procesamiento de imágenes cada ojo se mueve independientemente en un continuo temblor de alta frecuencia (pico 80Hz), y baja amplitud (150-2500nm), causando una imagen que nunca se detiene en la retina respectiva (Sheahan, 1993). Aunque costoso en términos de uso de energía y refinamiento del control, OMT provee la ventaja obvia de ver y reconocer objetos que permanecen estacionarios. OMT juega un papel central en la percepción visual de los mamíferos (Martinez-Conde, 2004) y está estrechamente asociado con el estado funcional del tronco cerebral. Investigadores han utilizado lecturas del OMT para diagnosticar y prevenir enfermedades cerebrales y como método inequívoco de confirmar la exipiración del tronco cerebral (Bojanic et al. 2001; Ciaran, et al. 1999).

En este trabajo creamos un OMT artificial el cual es posteriormente usado como fuente primordial de información por otros procesos neurales, con el propósito combinado de reconocer y seguir a un objeto específico del mundo real entre un set infinito de otras posibles imágenes, un problema de probada dificultad. (N. Pinto, 2008).

Las redes neurales han sido usadas extensivamente el seguimiento y reconocimiento de objetos (Yilmaz et al. 2006; Latha et al. 2008).

En este trabajo presentamos dos mecanismos neurales dinámicos que cooperan para mejorar las capacidades de reconocimiento del sistema. El primero establece un aprendizaje progresivo en el cual las sinapsis nunca se usan todas al mismo tiempo y el segundo un sistema de seguimiento rápido que produce un temblor ocular. Soluciones cooperativas similares han sido estudiadas en (Chang, 2009).

VISIÓN ARTIFICIAL

Uno de los grandes retos de la robótica contemporánea, sigue siendo el dotar a los robots con el sentido de la visión; es decir, incorporar al robot un sistema de procesamiento de imágenes autónomo, local y confiable que le permita moverse eficientemente en el mundo real, usando quizás una cámara web convencional como ojo digital.

Dentro de las facultades del robot, debe estar la capacidad de reconocer mediante su sistema de visión a un objeto o “señal” único y específico, como por ejemplo una silla o un signo de “pare” o un indicador de velocidad. El problema base es que en los sistemas de visión el número de posibles imágenes (dominio) crece exponencialmente con el número de sensores y alcanza rápidamente valores cuasi infinitos aun para la más modesta imagen captada con una cámara web (N. Pinto, 2008).

En este caso se plantea un sistema de visión artificial en el cual dos redes neurales artificiales entrenadas por diferentes métodos, cooperan para procesar imágenes y promover así el fiel seguimiento y reconocimiento de un objeto específico del mundo real. La cooperación entre entes neurales parece ser un proceso común en los cerebros biológicos (Anderson et al. 2010).

Nuestro sistema comprende dos redes neurales artificiales conectadas en cascada, que colaboran en el manejo de data masiva de imágenes y son entrenadas en diferentes periodos y con diferentes ambientes de aprendizaje. La primera red, llamada la red seguidora, se especializa en determinar la posición absoluta de un objeto seleccionado cuya imagen se recibe como una secuencia de cuadros de video. Esta imagen se desplaza en una retina móvil artificial creada con rutinas de OpenCV (librería de programación en lenguaje C especializada en manejar imágenes). La red seguidora es entrenada en un mundo digital finito, hasta que aprende a seguir al objeto seleccionado, aunque éste cambie en posición, inclinación (tilt) y escala. Para este fin se usa una forma especial de aprendizaje por gradiente (backpropagation) en el cual los pesos de conexión de la red (sinapsis) son distribuidos en el espacio tiempo durante el aprendizaje. Una vez entrenada, esta red participa en un

sistema de control a lazo cerrado en el cual las imágenes de entrada controlan directamente el desplazamiento de la retina móvil. Esta combinación induce en nuestro sistema electrónico de visión un OMT parecido al encontrado en el ojo de los mamíferos. Seguidamente a este sistema de control a lazo cerrado, se le otorga una completa libertad de operación, convirtiéndose en un ente independiente dentro del procesador neural global. Con esta estación de trabajo independiente en operación una segunda red, llamada la red reconocedora, es puesta en acción. Este nuevo sub procesador neural opera en forma independiente y se especializa en analizar en el tiempo espacio los micros temblores generados por la red seguidora. Para incorporar a la variable tiempo se usa a un grupo de elementos de memoria de corta duración. La red reconocedora posee una neurona de salida única cuya responsabilidad es producir una respuesta fuerte siempre que el objeto seleccionado esté presente en la secuencia de cuadros de videos recibidos, y una respuesta débil si no lo está. El mapeo de un objeto a una neurona se le llama “célula concepto” y se ha convertido en un tópico importante en recientes investigaciones sobre el funcionamiento del cerebro humano. (Quiroga, 2005).

El trabajo está organizado como sigue: en la sección 1 se desarrolla un método de entrenamiento progresivo que utiliza backpropagation en una manera dosificada y selectiva, haciendo posible adquirir nuevas habilidades de procesamiento sin destruir habilidades previamente adquiridas (pesos de conexión). En la sección 2 las redes altamente entrenadas de la sección anterior se ponen a trabajar con imágenes del mundo real, haciendo que éstas controlen la posición del ojo, generando de esta forma un OMT artificial y complejo. En la sección 3 una segunda red entrenable es introducida para analizar los micros temblores y producir una decisión única acerca de la presencia del objeto seleccionado (célula concepto).

METODOLOGIA

1. Red trazadora

En la Figura 1 se muestra el esquema utilizado en la red trazadora. Se escoge un helipad como objeto de estudio porque este elemento es frecuentemente empleado en problemas de visión artificial y en procesos de aterrizaje automático. (Mondragón, 2010; Mahoor et al. 2011; Ollero & Merino, 2004; Saripalli et al. 2002). Un helipad es una representación estándar en forma de H con un círculo alrededor que se utiliza para ayudar a los pilotos de helicópteros a realizar el proceso de aterrizaje por visión (Figura 1).

La red trazadora está formada por neuronas sigmoideas, es decir:

$$o(i) = \frac{1}{1 + e^{-x}} \quad (1)$$

dónde: x es el potencial interno de la neurona i .

Estas neuronas se organizan en tres capas. La primera capa (entrada) es una retina de 100x100 pixeles, consumando así un universo de 10.000 neuronas. Esta retina equivale en openCV a una “región de interés” o ROI, que es una sub imagen rectangular dentro de lo obtenido por la webcam y que puede ser desplazada a voluntad por el programador.

La segunda capa (escondida) comprende 25 neuronas y la tercera capa (salida) 22 neuronas, estas últimas congregadas en dos segmentos D_1 y D_2 , de 11 neuronas cada uno. Cada segmento se comporta como un clasificador independiente e indica la posición absoluta de la imagen del helipad con respecto al centro de la retina en los ejes x, y respectivamente, y con ± 5 pixeles de resolución.

En su modo operativo la red se comporta de la siguiente manera:

Por cada imagen recibida (cuadro o “frame” de video) se ejecuta el “feed forward” de la red y se obtienen 22 salidas analógicas en el rango 0-1.

Se aplica un criterio de selección de manera que la neurona con el más alto valor en cada segmento sea tomada como ganador y sea esta neurona la que decida la respuesta de la red (winner takes all). Una vez encontrado el ganador único por segmento se aplica la fórmula:

Segmento 1:

$$\text{if } \text{winner} = i \quad \text{then } x = i - 6 \quad (2)$$

dónde: x representa el número de pixel a los que, según la red, está desplazada la imagen en el eje x . Ya que i varía entre 1 y 11, x varía entre -5 y 5.

segmento 2:

$$\text{if } \text{winner} = j \quad \text{then } y = j - 17 \quad (3)$$

dónde: y representa el número de pixel a los que esta desplazada la imagen en el eje y . Ya que j varía entre 12 y 22, y varía entre -5 y 5.

Nótese que la red está obligada a dar una respuesta por cada imagen recibida. Si las imágenes y los pesos de conexión son aleatorios, entonces la salida de la red será aleatoria entre ± 5 píxeles por eje y por video frame.

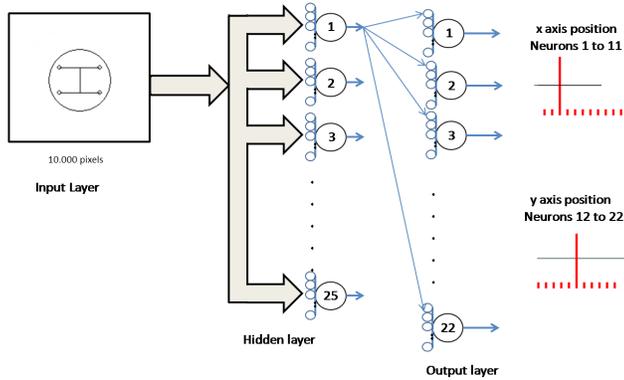


Figura 1. Red trazedora

Por topología de la red existen 10.000 pesos de conexión entre la retina de entrada y cada una de las neuronas de capa escondida. Para fines de entrenamiento, esta cantidad de pesos se divide, para cada neurona j de la capa escondida, en tres grupos independientes (G_1 , G_2 y G_3) esparcidos equilibradamente en el área de la retina según la fórmula periódica:

$$w_{ij} \in G_1 \text{ if } i = \text{múltiplo de } 3; \quad (4)$$

$$\text{para } i = 1, 2, 3, \dots, 10000$$

$$w_{ij} \in G_2 \text{ if } i = (\text{múltiplo de } 3) + 1; \quad (5)$$

$$\text{para } i = 1, 2, 3, \dots, 10000$$

$$w_{ij} \in G_3 \text{ if } i = (\text{múltiplo de } 3) + 2; \quad (6)$$

$$\text{para } i = 1, 2, 3, \dots, 10000$$

donde: i es el índice de la neurona de entrada y j el índice de la neurona escondida.

A partir de ahora el aprendizaje mediante backpropagation se realizara en tres fases progresivas y separadas y en cada fase se utilizara un y solo un grupo. El objetivo final de este entrenamiento progresivo es hacer que la red indique, mediante la actividad de sus neuronas de salida, la posición absoluta del helipad en la retina.

2. Entrenamiento de la red trazedora

Fase 1. La red comienza con pesos aleatorios. La imagen del helipad se ubica en el centro de la retina y se desplaza aleatoriamente ± 5 píxeles en cada eje con respecto al centro de la misma. A los targets se les activa de manera que solo dos de ellos están en 0.9 mientras que los restantes están en 0,1. Los dos targets en 0,9 indican exactamente los

desplazamientos aleatorios en los ejes x , ya los que ha sido sometida la imagen del helipad. Durante esta fase, no se cambian, ni la escala ni el giro de la imagen, y para fines de aprendizaje se utiliza únicamente a pesos de G_1 ; es decir, el primer tercio de los 10000 pesos de conexión que tiene cada neurona j de capa escondida con la retina.

Fase 2. Se continúa con el desplazamiento de la imagen del helipad en ± 5 píxeles en cada eje, pero ahora se admite un giro de ± 10 grados con incrementos de un grado. Los pesos hallados en la fase 1 (grupo G_1) son “congelados” y no pueden ser tocados por el nuevo proceso de backpro, que ahora sólo modifica a G_2 .

Fase 3. Se continúa con el desplazamiento de la imagen del helipad en ± 5 píxeles en cada eje, se admite el giro de ± 10 grados de la fase 2 y se añade una variación de escala de 3:1, es decir el tamaño del helipad varía en tamaño de 1 a 3. Los pesos hallados en las fases 1 y 2 (grupos G_1 y G_2) son congelados y ahora el backpro sólo modifica a G_3 .

3. Generación del OMT

Una vez entrenada la red trazedora, sus salidas son usadas para que imágenes del mundo real controlen el movimiento del ojo. Este es un tipo de control proporcional en el cual el valor de desplazamiento calculado por la red se le suma a las coordenadas actuales del centro del ojo. En nuestro caso, trabajando con la librería OpenCV, este movimiento se ejecuta cambiando las coordenadas de la “región de interés” o ROI de la imagen, según se explicó antes. En definitiva la ROI alimenta a la red trazedora y ésta mueve a la ROI. El resultado es un movimiento “tembloroso” en el que el ROI se desplaza en forma cuasi aleatoria un máximo de ± 5 píxeles por cada cuadro de video (frame) que se procesa (Figura 2). Una vez que la red entra en este estado tembloroso, sus 22 salidas analógicas se almacenan en una memoria FIFO con diez registros de profundidad, produciendo una matriz espacio tiempo con 22 columnas (vector de salida de la red) y 10 filas (instantes de tiempo consecutivos, cuadros de video o frames). Esto es:

$$M = \begin{bmatrix} e_{1,1}, e_{1,2} & \cdots & e_{1,21}, e_{1,22} \\ \vdots & \ddots & \vdots \\ e_{10,1}, e_{10,2} & \cdots & e_{10,21}, e_{10,22} \end{bmatrix} \quad (7)$$

donde: e_{ij} es el valor de la neurona (de salida) j en tiempo (frame) i .

4. Red Reconocedora

A continuación se define una segunda red (Figura 3) cuyas

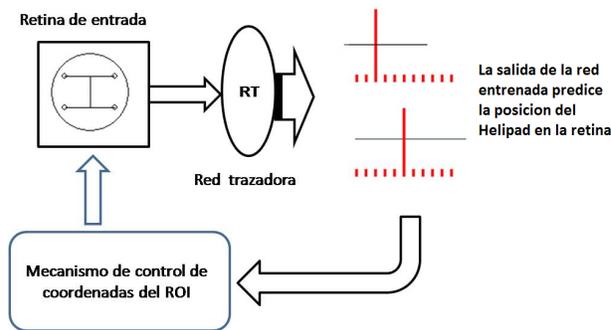


Figura 2. Generación del OMT

entradas son los 240 elementos e_{ij} de la matriz M descrita en la sección anterior, su capa escondida contiene 19 neuronas y su capa de salida posee una única neurona, encargada de activarse sólo cuando el helipad está presente. Esta última neurona equivale a la “Célula Concepto”, descrita en la literatura del comportamiento del cerebro humano (Quiroga, 2005).

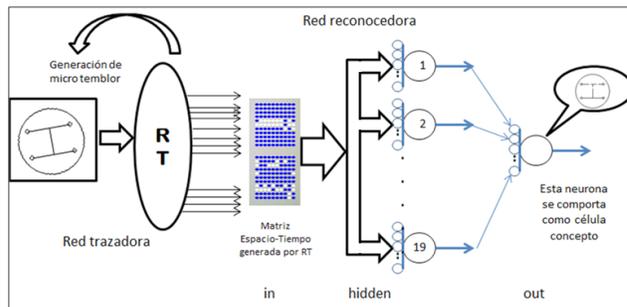


Figura 3. Red reconocedora

5. Entrenamiento de la red reconocedora

Para entrenar a esta segunda red un operario humano le muestra -mediante la webcam- diferentes objetos y situaciones del mundo real. Si el objeto es el helipad y la red no responde, se disparan 50 ciclos consecutivos de backpro, con el único target en 0,9. Si el objeto no es el helipad pero la red responde afirmativamente, se disparan 50 ciclos consecutivos de backpro con el target en 0,1.

Normalmente la red aprende rápidamente y responde en forma segura con unos 250 ciclos de backpropagation en cada valor del target.

RESULTADOS Y DISCUSION

A través de muchos experimentos prácticos, en los cuales se cambian sistemáticamente diferentes parámetros del aprendizaje -tales como número de neuronas, tamaño de la imagen, ganancia, entre otros- la única manera aparente de aprender cambios simultáneos en posición, inclinación y escala es usando el aprendizaje progresivo descrito, en

el cual los pesos de la capa escondida se distribuyen en el espacio y el tiempo durante el aprendizaje. Parece, por lo tanto, conveniente cuando se aprende un tema complejo, preservar formas básicas de aprendizaje en un estado de congelación mientras se memorizan variaciones de un mismo tema.

En la fase 1 del aprendizaje, usando solo 1/3 de las sinapsis (pesos), el aprendizaje es convergente y después de unos 5000 ciclos de backpro la red se entrena en forma casi perfecta, hasta que el error global disminuye hasta un 0,1 %. Cuando comienza la fase 2 el error sube bruscamente a un 15% y después de 5000 ciclos baja de nuevo a 0,15.

En la fase 3 de nuevo el error salta hasta 17% y luego regresa a 0,17%.

Nuestros experimentos también demuestran que ser un excelente reconocedor en el mundo finito, no garantiza que se pueda ser buen reconocedor en el mundo real, a menos que se añadan recursos neurales extras.

Cuando se realimente la salida de la red seguidora al control de posición del ROI, se genera un OMT. Esta condición de lazo cerrado también da origen a un sistema robusto y autónomo con comportamiento en el espacio tiempo complejo y ruidoso (Figura 4), Es notable que a partir de este caos aparente, una segunda red finita pueda extraer suficiente información confiable y así resolver las infinitas variaciones del mundo real produciendo un reconocimiento dinámico y confiable del helipad, cuyas imágenes contienen intrincados cambios en posición, inclinación y escala. El procesamiento también rechaza exitosamente todas las otras imágenes que no sean helipad y parece difícil engañarlo hacia una detección falsa. Por ejemplo en un experimento de larga duración (tres horas) se mostraron imágenes aleatorias tomadas de un periódico común y el error fue de aproximadamente 0,35; es decir, de mil imágenes mostradas en forma dinámica sólo 3 de ellas fueron tomadas errónea y momentáneamente como helipads.

(En la Figura 5, se muestra una imagen real de seguimiento y reconocimiento http://www.youtube.com/watch?v=7p_VPvQ2clw).

Se han hecho experimentos preliminares con otros objetos, tal como un rostro humano y la respuesta es igualmente confiable.

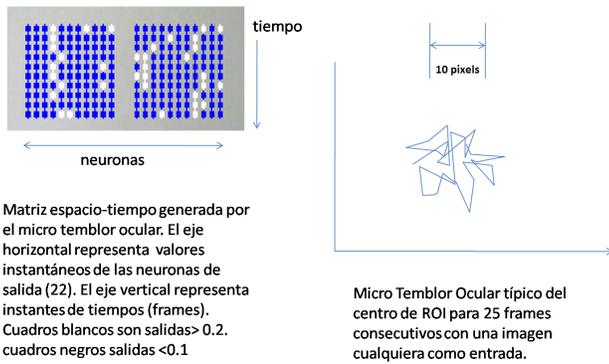


Figura 4. Patrones complejos OMT en el espacio tiempo

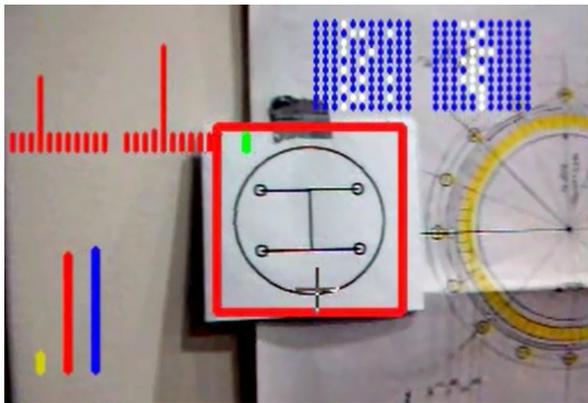


Figura 5. Imagen real de seguimiento y reconocimiento del Helipad

El recuadro rojo representa la retina de entrada del sistema. La barra roja inferior izquierda representa la salida de la neurona concepto (en su máximo valor). Las dos matrices azules en la parte superior son el resultado espacio-tiempo del OMT.

CONCLUSIONES

Al igual que en el mundo biológico, el sistema propuesto correlaciona estrechamente al OMT con el reconocimiento confiable de un objeto.

El aprendizaje progresivo desarrollado parece ser un medio eficiente para aprender variaciones del mismo tema, en nuestro caso un helipad y sus muchísimas pero virtuales y finitas variaciones en posición, inclinación y escala. En las imágenes del mundo real, captadas por la cámara web, las variaciones son prácticamente infinitas. Aun así el aprendizaje virtual finito es suficiente para manejarlas cuando una nueva condición dinámica u OMT es añadida y así lo demuestran los resultados.

De acuerdo con nuestros experimentos la presencia de objeto seleccionado produce en el OMT una especie de estado resonante, fácilmente reconocible por otra red neural.

Al menos para el sistema propuesto el seguimiento precede al reconocimiento y no al contrario. Los resultados obtenidos son comparables con resultados de otros sistemas neurales entrenables (Gomez et al.2006) en los cuales se reportan tasas de acierto de hasta 98%.

Finalmente probamos que es posible descomponer el proceso de identificar a un objeto móvil y complejo en dos sub procesos neurales conectados en cascada donde el primero se controla a sí mismo y en el interin genera valiosa información espacio-tiempo para un segundo proceso “concepto”. Dentro de rangos operativos esta combinación parece manejar efectivamente la complejidad de la visión en el mundo real.

Se espera expandir este trabajo a aplicaciones con importante contenido social como lo son medicina, agricultura, medio ambiente, construcción civil, seguridad, aplicaciones militares entre otros.

REFERENCIAS

- ANDERSON, M., BRUMBAUGH, J., & SUBEN, A. (2010). Investigating Functional Cooperation in the Human Brain Using Simple Graph-Theoretic Methods. (Computational neuroscience. Springer New York, 2010. 31-42.) Retrieved from http://content.schweitzer-online.de/static/content/catalog/newbooks/978/038/788/9780387886299/9780387886299_Excerpt_001.pdf.
- BOJANIC, S., SIMPSON, T., & BOLGER, C. (2001). Ocular microtremor: A tool for measuring depth of anaesthesia? *Br J Anaesth*(86), 519-22.
- BROOKS, R. (1991). “Intelligence without representation”. *Artificial Intelligence*, 139-159.
- CHANG, O. (2009). Evolving cooperative neural agents for controlling vision guided mobile robots. *Proceedings of 2009 8th IEEE International Conference on Cybernetic Intelligent Systems*, Birmingham University, UK.
- CIARAN, B., BOJANIC, S. B., PHILLIPS, J. M., SHEAHAN, N. P., COAKLEY, D. M., MALONE, J. P. (1999). Ocular Microtremor in Brain Stem Death. *Neurosurgery*: June 1999 - Volume 44 - Issue 6 - pp 1201-1206.
- GOMEZ, N., ALQUEZAR, R., SERRATOSA, F. (2006). Object Recognition and Tracking in Video Sequences: A New Integrated Methodology. 4225.

- LATHA, P., GANESAN, L., RAMARAJ, N., VENKATESH, P. V. (2008). Detection of Moving Images Using Neural Network. *World Academy of Science, Engineering and Technology*, 22.
- MAHOOR, M., GODZDANKER, R., DALAMAGKIDIS, K., VALAVANIS, K. P. (2011). Vision-Based Landing of Light Weight Unmanned Helicopters on a Smart Landing Platform. *Journal Intelligent Robot Systems*, 61, 251–265.
- MONDRAGÓN, I. A.-M. (2010). 3D pose estimation based on planar object tracking for UAVs control. In P. IEEE (Ed.), *Robotics and Automation ICRA2010*. (pp. 35-41). Anchorage, Alaska, USA: IEEE International Conference on.
- MORAVEC, H. (1984). Locomotion, vision and intelligence. 215-224.
- N. PINTO, D. D. (2008). Why is real-world visual object recognition hard? *PLoS Comput Biol*, Vol4, No. 1, p.e27.
- OLLERO, A., & MERINO, L. (2004). Control and perception techniques for aerial robotics. *Annual Reviews in Control*, 28, 167-178.
- OLMSTED, D. (2006). <http://neurocomputing.org>. Retrieved from [<http://neurocomputing.org/frogeye.aspx>].
- QUIROGA, R. (2005). Invariant visual representation by single neurons in the human brain. *Nature*, 6/23/2005, Vol. 435 Issue 7045, p1102-1107, 6p; doi:10.1038/nature03687;.
- S. MARTINEZ-CONDE, S. L. (2004). The role of fixational eye movements in visual perception. *Nature Reviews Neuroscience* 5, 229-240 (March 2004) | doi:10.1038/nrn1348.
- S. SAW, S. T. (2004). IQ and the association with myopia in children. *Invest Ophthalmol Vis Sci*, 45(9), 2943-8.
- SARIPALLI, S., SUKHATME, G., MONTGOMERY, J. (2002). An Experimental Study of the Autonomous Helicopter Landing Problem. In 8. I. Robotics (Ed.), http://robotics.asu.edu/sri/Publications_files/iser2002.pdf. Sant'Angelo d'Ischia, Italy.
- SEANSEANG-M., S.-B. T. (2004). IQ and the Association with Myopia in Children. *Investigative Ophthalmology and Visual Science*, Vol. 45, No. 9.
- SHEAHAN, N. F. (1993). Ocular microtremor measurement system: design and performance. *Med Biol Eng Comput* 31(3): 205-12, 31(3).
- YILMAZ, A., JAVE, O., M.SHAH. (2006). Object Tracking: A Survey. *ACM Comput. Surv.* 38, 4, Article 13, 45 pages.