

Extracción de características morfológicas de fibra textil mediante un algoritmo de Memoria Temporal Jerárquica

Arcidiácono, Marcelo J. M.
Universidad Tecnológica Nacional
Facultad Regional Córdoba

Destefanis, Eduardo A.
Universidad Tecnológica Nacional
Facultad Regional Córdoba

Resumen

En el marco de la sustentabilidad productiva de fibra textil de origen animal, contar con un método automatizado, ágil y seguro que permita obtener una medida de calidad, resulta sumamente valioso para los productores rurales. Tal medida de calidad puede obtenerse a partir del diámetro de la fibra. En la imagen obtenida a partir de una muestra existen diversas estructuras características del tipo de fibra y otros factores particulares asociados a la captura de la imagen. Todas estas variables deben poder ser catalogadas e identificadas para extraer aquellos objetos que resultan útiles antes de ser procesados. En este trabajo, se aplica un método de extracción de características morfológicas útiles, basado en un modelo del neocórtex humano.

Introducción

Tanto la identificación como la caracterización de pelos y fibras de origen animal, adquiere importancia relevante en el análisis y estudio de sus propiedades para usos textiles e industriales e incluso artesanales [7]. Se estima que más de un millón de pequeños productores de los Andes centrales en Sudamérica tienen alpacas y llamas como principal medio de subsistencia. Estos animales proveen carne, leche, fibra, energía de transporte y guano y, además, constituyen un elemento importante de la identidad cultural de sus pueblos. Poblaciones definidas de estos camélidos califican para ser capturadas, esquiladas y liberadas generando un ingreso adicional a las comunidades en que viven. El aumento de la producción de fibras y demás productos de camélidos sudamericanos, a la vez de preservar un recurso genético animal crítico y los valores culturales asociados y mejorar la calidad de vida de muchos pequeños productores, debe ser parte de una estrategia global de inversión sostenida en investigación y desarrollo.

El Programa SUPPRAD de la Facultad de Ciencias Agropecuarias de la Universidad Católica de Córdoba, vinculado con instituciones y cooperativas agrícolas y ganaderas, tanto nacionales como internacionales [18], lleva adelante, desde hace algunos años, proyectos para identificar objetivos de mejoramiento de las cualidades de sustentabilidad

para la producción de pequeños rumiantes y camélidos en áreas desfavorecidas. Por otro lado, en años recientes, la investigación en el ámbito de la industria textil ha recibido un nuevo impulso a través del proyecto de Desarrollo Tecnológico de Procesos y Productos Innovadores para la Cadena de Valor de Camélidos, presentado por el INTI (Intituto Nacional de Tecnología Industrial) y aprobado por la Agencia Nacional de Promoción Científica y Tecnológica en abril del 2013 [4].

El proyecto de investigación RNA-SU del Departamento de Ingeniería en Sistemas de Información junto al Centro de Investigación en Informática para la Ingeniería de la Universidad Tecnológica Nacional, Facultad Regional Córdoba, colabora con el SUPPRAD en su objetivo de acercar la tecnología a productores rurales en áreas desfavorecidas, proporcionándoles herramientas para medir la calidad de la fibra textil a bajo costo.

En la República Argentina, el Programa Nacional “Fibras Animales” considera de gran valor la comercialización, producción, e industrialización de lana, mohair, cashmere, llama, guanaco y vicuña [16]. El valor de la fibra textil está dado, fundamentalmente, por su finura promedio además de otras propiedades que hacen a establecer su cotización tales como el índice de confort PF (*Prickle Factor*) que constituye el porcentaje de fibras con diámetros mayores a 32 micrones, la presencia o ausencia de medulación, el crimpado y la forma y altura de las escamas [1]. Para determinar una medida satisfactoria de calidad de la fibra textil de origen animal, además de tener en cuenta defectos obvios como la pigmentación y la presencia de fibras atípicas o meduladas [5], la característica de mayor importancia es el diámetro medio. Fibras más finas tienen más aplicaciones industriales y en consecuencia tienen mayor valor económico [15]. Reconocer y poder mediar apropiadamente cada tipo de fibra, constituye el objetivo de este trabajo.

Elementos del Trabajo y metodología

El problema del reconocimiento de imágenes parece ser simple a primera vista, pero a menudo es difícil de resolver. No hay una manera obvia de manejar estos problemas y existen muchas técnicas diferentes. El reconocimiento visual de patrones, tal como la lectura

de caracteres o la discriminación de formas, es una tarea sencilla y natural en seres humanos. La verdadera dificultad es diseñar un algoritmo computacional capaz de hacer esto de la misma manera. Posiblemente, una de las mejores estrategias sea aprender del propio cerebro, estudiando el mecanismo con el que se procesa la información visual y tratando de usarlo en el principio de diseño de nuevos procesadores de información. Más precisamente, cómo puede sintetizarse una red neuronal que tenga la misma habilidad que el cerebro humano.

Un resultado de dicha aproximación en el reconocimiento de patrones es el llamado “neocognitrón” [8]. En el área visual del cerebro, se encontraron neuronas que responden selectivamente a características locales de un patrón visual tales como líneas y bordes y, en particular, orientaciones [14]. En la zona más alta de la corteza visual, existen células que responden selectivamente a ciertas figuras como círculos, triángulos, cuadrados o incluso al rostro humano [2]. De acuerdo a esto, el sistema visual parece tener una estructura jerárquica en la que primero se extraen características simples de un patrón estímulo y luego se integran las características más complejas. En esta jerarquía, una celda en una capa superior generalmente recibe señales desde un área más amplia de la retina siendo insensible a la posición del estímulo.

En este trabajo estudiamos y aplicamos una nueva estrategia basada en el modelo del neocórtex humano: Memoria Temporal Jerárquica (*Hierarchical Temporal Memory* HTM) [11]. El HTM fue propuesto por Jeff Hawkins y modela algunas de las estructuras y propiedades algorítmicas del neocórtex. El HTM es un modelo biométrico basado en la teoría de memoria y predicción de la función cerebral descrita en [12]. Es un método para descubrir e inferir las causas de alto nivel de los patrones y secuencia de entrada observados, construyendo así un modelo cada vez más complejo del mundo. El HTM combina y se extiende a enfoques utilizados en redes bayesianas y algoritmos de agrupación espacial y temporal mediante el uso de una jerarquía en forma de árbol de nodos, común en las redes neuronales. El HTM se ha utilizado con éxito para el reconocimiento de objetos [3] [9] ya que el proceso de construcción de mapas de la realidad tiene características intrínsecamente similares a la de identificación de objetos. Al tratar el problema de identificación de fibras como un problema de reconocimiento espacial, proponemos resolverlo con un algoritmo basado en una Red HTM.

A. Memoria Temporal Jerárquica

El HTM proporciona un marco teórico para la comprensión y entendimiento de cómo funciona el neocórtex. Se cree que explica cómo los seres

humanos aprenden, identifican objetos y patrones y hacen predicciones. El HTM se puede ver como un tipo de red neuronal. En el corazón de cada red HTM existe un conjunto de algoritmos de aprendizaje llamados Algoritmos de Aprendizaje Cortical (*Cortical Learning Algorithm* CLA) [11] que modelan la organización y comportamiento de una capa de neuronas en el neocórtex. De la misma forma que los seres humanos aprenden del entorno, el CLA lleva a cabo la difícil tarea de descubrir la estructura temporal en grandes y complejas estructuras de datos (información sensorial secuencial). Mediante la observación de cómo los datos cambian con el tiempo, una red HTM aprende qué patrones son significativos y cuáles están relacionados causalmente.




Figura 1. Esquema de un HTM. Jerarquía en tres niveles más un nodo sensor (1). Nodos (2-5), primer nivel; nodos (6-7), segundo nivel; nodo (8), tercer nivel.

Un HTM se organiza en la forma de un árbol jerárquico en el que los niveles se componen de elementos más pequeños llamados nodos o columnas (figura 1). Un simple nivel en la jerarquía también se llama región. Cada región de un HTM consiste de un número de columnas corticales fuertemente interconectadas. Una columna cortical se entiende como un grupo de células que tienen el mismo campo receptivo. Cada columna tiene un número de células que puede recordar varios estados anteriores. Una célula HTM, en comparación con una simple neurona artificial, tiene una estructura más compleja. Simula y capta completamente muchas de las capacidades importantes de las neuronas reales [11], lo que hace adecuado al HTM para manejar datos complejos. Estas células están vinculadas entre sí en la misma

región y también interconectadas entre las diferentes regiones. Los niveles jerárquicos más altos tienen, a menudo, un menor número de nodos y por lo tanto menos capacidad de resolución espacial. Los niveles jerárquicos más altos pueden reutilizar patrones aprendidos en los niveles inferiores mediante su combinación para memorizar patrones más complejos.

Cada nodo tiene la misma funcionalidad básica [13]: el aprendizaje, la inferencia y la predicción. Los algoritmos de aprendizaje corticales son capaces de aprender continuamente de cada patrón de entrada. Los datos sensoriales entran en los nodos del nivel inferior y de los nodos del nivel inferior sale el patrón generado de una categoría dada. El nivel superior tiene, por lo general, un único nodo que almacena las categorías más generales (conceptos) que determinan, o bien son determinadas por, los conceptos más pequeños en los niveles inferiores más restringidos en el tiempo y el espacio. Durante la inferencia, el HTM, tiene como objetivo igualar las cadenas de entradas con fragmentos de secuencias previamente aprendidas. Un nodo en cada nivel interpreta la información que proviene de sus nodos hijos en los niveles más bajos como probabilidades de las categorías que tiene en la memoria. Cada región de un HTM aprende, por identificación y memorización espacial, combinaciones de patrones de entrada que a menudo ocurren al mismo tiempo (agrupación espacial). A continuación identifica las secuencias temporales de los patrones espaciales que es probable que se produzcan una tras otra (agrupación temporal). Esto permite que cada región HTM pueda predecir constantemente la probable continuidad de la secuencia reconocida. El índice de la secuencia predicha es la salida de una región. Debido a que las predicciones tienden a cambiar menos frecuentemente que los patrones de entrada, aumenta la estabilidad temporal de la salida en los niveles más altos. La predicción además ayuda a llenar los patrones faltantes en la secuencia e interpretar datos ambiguos, polarizando el sistema para inferir lo que se predijo. El aprendizaje y la inferencia son procesos de alimentación y la predicción es un proceso de retroalimentación.

La creación de una aplicación HTM difiere significativamente de un proceso de ingeniería de software tradicional. Las redes HTM aprenden por la construcción de un modelo estadístico basado en una secuencia de datos de entrada. La tarea del desarrollo de una aplicación no consiste en especificar un algoritmo, sino llegar a una representación adecuada de los datos y encontrar el valor de los parámetros óptimos para el problema en cuestión. El proceso de diseño del HTM utilizado en este trabajo, se muestra en la figura 2. Formular y refinar el problema de manera tal que de buenos resultados, es una parte importante del ciclo de desarrollo de un HTM. A

menos que los datos se representen de una forma que resulte fácil de entender para un HTM (y con los seres humanos pasa lo mismo), los resultados, probablemente, no serán satisfactorios.

B. Implementación del modelo

La implementación del modelo aplicado en nuestro estudio, se basa en una combinación de un HTM con un modelo de Vector de Características Visuales (Visual Feature Array VFA) propuesto en [17], que consiste de un arreglo ortogonal de unidades computacionales que responden a diferentes



Figura 2. Proceso de diseño de la aplicación HTM.

características visuales tal como es el caso de las neuronas encontradas en la corteza visual primaria. El VFA contiene valores que representan la salida computacional de elementos correspondientes a ciertas posiciones. $VFA(x, y, z)$ con dimensiones $x \times y \times z$ se generan desde una imagen bidimensional de tamaño $u \times v$ representada por la función $f(u, v)$, donde:

$$f(u, v) \in \mathbb{N}, [0..255] \quad (1)$$

$$(u, v) \in \mathbb{N}^2, [0..U] \times [0..V] \quad (2)$$

$$VFA(x, y, z) \in \mathbb{N}, [0..255] \quad (3)$$

$$(x, y, z) \in \mathbb{N}^3, [0..X] \times [0..Y] \times [0..Z] \quad (4)$$

$VFA(x, y, z)$ es la salida de la unidad computacional que corresponde a las coordenadas (x, y) de la imagen y es sensible a ciertas características de la imagen

representadas en z . La versión usada en este estudio, puede ser vista como una colección de capas apiladas una sobre la otra en la que cada una (un arreglo bidimensional) representa la isoorientación de los elementos del contorno [17]. Las capas vecinas contienen elementos de contorno con la orientación de sus vecinos. Debido a que los filtros utilizados en las redes neuronales biológicas son a menudo difusos y no son precisos los valores en los VFA son por lo general borrosos entre capas vecinas. Para aliviar este problema en una forma similar a los mecanismos biológicos, se introduce una inhibición lateral entre los elementos computacionales de cada capa y aquellos de las capas vecinas como se describe en [6].

La representación de los datos computacionales usados por los modelos de VFA presentan una detección rápida de ciertas características visuales con un muy bajo costo computacional. Un ejemplo típico es la detección de intersecciones de segmentos lineales. Lo cual resulta sumamente útil en la detección de intersección de fibras. Sea V^{18} un vector que contiene 18 elementos. Los valores de V^{18} corresponden a la salida de simples células pertenecientes a un punto de la imagen dada. Así, 180° de orientación se cubren en incrementos de 10° grados.

$$V_{xy}(i) = VFA(x, y, \phi_i), \phi_i = 1, 2, 3, \dots, 18$$

Las intersecciones se pueden detectar como sigue:


$$N(x, y) = \text{signum}\left\{\sum_{j=1}^{18} V_{xy}(j) - c\right\}$$

Donde c es un valor umbral.


Con el fin de probar nuestro modelo HTM con una entrada obtenida desde un modelo VFA, usamos un set de imágenes construidas a partir de un patrón esquemático de una fibra en corte longitudinal no medulada de llama, variando su orientación de 0° a 45° en pasos de 5° y espejando dichas imágenes de forma tal de obtener un conjunto de 30 imágenes de entrenamiento. Se utilizaron cuatro imágenes de prueba de 512×512 , las que fueron obtenidas a partir de la imagen de la figura 3 (de 1024×1024), una imagen de bacilos y una imagen de gusanos.

Las imágenes usadas para prueba y entrenamiento tenían el mismo tamaño. Se calculó en VFA para cada imagen. El método utilizado para probar el rendimiento del HTM fue el hacer una sumatoria a lo largo del tercer eje y luego hacer una normalización con el objeto de obtener valores entre 0 y 1. Luego, todas las regiones 8×8 fueron desarticuladas y sustituidas por el promedio de sus valores.

(a)



(b)



(c)



Figura 3. (a) Corte longitudinal de fibra de llama cedida por el Dr. E. Frank. Laboratorio SUPPRAD, con fines de investigación. (b) Mycobacterium tuberculosis perfringens o bacilos de Koch. (c) Pieris phileta o gusano de la col.

Esto dio como resultado imágenes de 64×64 píxeles, las cuales, cuando se leen pixel a pixel de forma topológica, producen vectores filas de 4096 elementos. Cada imagen así obtenida, puede verse como una onda de forma tridimensional (las dos primeras dimensiones corresponden a las dimensiones de la imagen, y la tercera es definida por el valor de cada píxel). Cada imagen de entrenamiento fue desplazada 10 píxeles, un pixel a la vez en cuatro direcciones (norte, sur, este y oeste). Este desplazamiento se hizo con el propósito de obtener un alto nivel de invarianza al entrenar la red. De esta forma, los nodos de la red pueden aprender que dos instancias desplazadas de la misma imagen se originan en una misma causa.

La Red HTM usada en nuestro experimento se creó usando la plataforma Numenta, desarrollada por Numenta Inc. Es un entorno hecho en JAVA que puede ser utilizado para crear una aplicación

personalizada. La Red HTM usada tiene tres capas y las celdas de procesamiento en cada capa se disponen de una forma topológica. Esto significa que las unidades de procesamiento vecinas en cada capa L alimentan con su salida a las mismas unidades de procesamiento en la capa $L + 1$ en la jerarquía y reciben su entrada de las mismas áreas vecinas de la imagen.

Parámetros Utilizados:

Capa 1:

- levelSize = 64
- pooler algorithm: *gaussian*; sigma = 0.4
- maxDistance = *variable*
- maxGroupSize = 1435
- grouper algorithm: *sumProp*

Capa 2:

- levelSize = 4
- pooler algorithm: *product*
- maxGroupSize = 1435
- grouper algorithm: *sumProp*

Capa 3:

- levelSize = 1
- pooler algorithm: *product*
- mapper algorithm: *sumProp*

maxDistance en la primera capa define el valor de cuadrados mínimos de las distancias Euclideas entre una entrada (x) y todas las entradas previamente memorizadas (y_i) que deben tomarse en cuenta para considerar a (x) novedosa. *maxGroupSize* establece un límite superior para cuantizar el número de entradas que pueden formar un grupo en el agrupamiento temporal. El algoritmo usado por el agrupamiento espacial de los niveles más altos es *product*, esto significa que la creencia de que una entrada durante la fase de inferencia sea similar a un vector determinado (previamente memorizado por el agrupamiento espacial) se calcula:

$$belief f_i = \prod_{j=1}^{nchildren} y_i[child_j] * x_j[child_j]$$

Donde *nchildren* es el número de hijos que tiene el nodo, x es el vector de entrada, y_i es el vector previamente memorizado por el agrupamiento espacial y $a[child_n]$ es la parte del vector a que es recibido desde el n ésimo hijo. Finalmente, el agrupamiento temporal de cada nivel usa el algoritmo *sumProp*, el que toma la más alta expectativa de cada grupo para generar una distribución de creencias sobre grupos temporales durante la inferencia.

Al presentar una imagen de prueba, la salida de nivel superior es una distribución que indica la certeza de la Red en reconocer la imagen dentro de una cierta categoría. Además de reconocer patrones de entrada, la Red HTM propaga la información en la jerarquía usando técnicas de propagación de creencias tal como se describen en [10]. La retroalimentación de información se utiliza para segmentar el objeto y localizarlo en la imagen. En este caso la red reconoce una imagen estática. Este es el caso especial en el que los cálculos de programación dinámica descriptos utilizan sólo un único instante de tiempo para la inferencia. (Las redes HTM necesitan patrones que varían en el tiempo para aprender, y el modo general de operación es el de desarrollar inferencia sobre la variación en el tiempo de los patrones de prueba. De cualquier forma, en los problemas de reconocimiento de imágenes, hay suficiente información para lograr inferir sin necesidad de usar patrones que cambian en el tiempo). En nuestro caso, el reconocimiento se obtuvo por una simple alimentación hacia arriba a través de la jerarquía de la red. Esto es consistente con observaciones acerca de la velocidad de procesamiento en el sistema visual humano [19].

Resultados

Luego de entrenar la Red con el set de entrenamiento antes mencionado, se presentaron a la Red las siguientes imágenes de prueba (figura 4).

Para la imagen 1, 2 y 4 se obtuvieron los porcentajes más altos de probabilidad de contener fibras de llama no meduladas, 0.984, 0.979 y 0.991 respectivamente.




Figura 4. Imágenes de prueba presentadas a la red para identificación de fibras no meduladas.




Figura 5. Probabilidad de la imagen de contener fibras de llama no meduladas.

Las imágenes fueron previamente procesadas para presentar a la Red un patrón más simple. A continuación se muestran las tres imágenes que lograron un puntaje mayor a 0.9 tal como fueron presentadas y debajo, los efectos de la propagación hacia abajo en la red HTM:




Figura 6. En la fila superior se indica la imagen que fue presentada a la Red, en la fila del medio puede apreciarse la forma en la que fueron estas presentadas. La fila inferior muestra las imágenes obtenidas luego de la propagación hacia abajo.

Discusión

La Red fue entrenada con un set de imágenes construidas a partir de un patrón esquemático de una fibra en corte longitudinal no medulada de llama. Los resultados obtenidos y mostrados en la figura 5, dan cuenta de la capacidad de la Red para reconocer el

patrón bajo estudio en las imágenes presentadas (1, 2 y 4) con una probabilidad mayor a 0.9. La imagen 3, que corresponde también a un corte longitudinal de fibra de llama, contiene una única fibra medulada, la probabilidad en este caso de contener fibras no meduladas es muy baja (0.253). En contraste, la imagen 5, con una probabilidad media (0.625), indica una tendencia en la Red a inferir como probable de contener el patrón. No obstante, acondicionado adecuadamente el umbral probabilístico, dicha imagen puede ser descartada del conjunto a medir en un proceso automático.

Conclusión

Los resultados obtenidos en este trabajo, con una estrategia basada en el modelo del neocórtex humano, implementado en una Red HTM con una estructura jerárquica de tres niveles, se presentan satisfactorios en cuanto a la identificación del patrón adecuado para obtener medidas de calidad de la fibra textil.

La representación de los datos usados con el modelo de VFA presentaron una detección rápida de las características morfológicas bajo estudio, con un muy bajo costo computacional. Esto facilitó la detección de intersecciones entre fibras. Lo cual resulta sumamente útil para la obtención de objetos útiles a ser incorporados en un proceso automático de medición.

Debido a que una Red HTM aprende por la construcción de un modelo estadístico basado en una secuencia de datos de entrada. La tarea más compleja en desarrollo de un algoritmo de esta naturaleza es la de llegar a una representación adecuada de los datos. No obstante, configurada la misma, esta representación permite entrenar a la Red con distintos patrones que correspondan a tipos distintos de fibras o características morfológicas relevantes de las fibras bajo estudio, definiendo el valor de los parámetros óptimos para el problema en cuestión.

Por último, cabe destacar que atendiendo a la problemática que presenta la determinación de la calidad de la fibra a partir del conocimiento de su finura, el método es útil por cuanto presenta características de buena performance, bajo costo de equipamiento y una vez configurado, no requiere operación por parte de personal calificado.

Referencias

- [1] Adot, O. (2010), "Introducción a la industrialización de la lana y las fibras especiales", Documento Interno SUPPRAD N°2.
- [2] Bruce, C., Desimone, R., & Gross, C. G. (1981). Visual properties of neurons in a polysensory

- area in superior temporal sulcus of the macaque. *Journal of Neurophysiology*, 46(2), 369-384.
- [3] Bundzel, M. & Hashimoto, S. (2010) "Object Identification in Dynamic Images Based on the Memory-Prediction Theory of Brain Function", *Journal of Intelligent Learning Systems and Applications*, vol. 2, pp. 212-220.
- [4] Cafagnini, M., Marino, P., Jater, N., Escobar, G., Takashima, C., Berterreix, C., Szombach, J., Olivero, M., Pacheco, R. (2013) "Desarrollo tecnológico de procesos y productos innovadores para la cadena de valor de camélidos", INTI Textiles, INTI Mecánica, UTN Bs. As.
- [5] Cancio, A., Rebuffi, G., Muller, J., Duga, L., Rigalt, F. (2006) "Parámetros cualitativos de la producción de fibras de llamas (*Lama Gama*) machos en la puna argentina", INTA EEA Bariloche, INTA AER Trancas, INTA EEA Catamarca, Comunicación Técnica, PA 492.
- [6] Csapó, A., Baranyi, P., Domonkos, T. (2007) "Object Categorization Using VFA-generated Nodemaps and Hierarchical Temporal Memories.", Conference Paper, IEEE Xplore.
- [7] Ford, J. & Roff, W. (1954) "Identification of textile and related fibers", *Journal of the Textile Institute Transactions*, 45:580-611.
- [8] Fukushima, K. (1980). Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*. 36(4), 193-202.
- [9] George, D. (2008) "How the brain might work: A hierarchical and temporal model for learning and recognition", Ph.D., Department of Electrical Engineering, Stanford University, California, USA.
- [10] George, D., Jaros, B. (2007) "The HTM Learning Algorithms." Numenta, Inc, Menlo Park, CA.
- [11] Hawkins, J., Ahmad, S. & Dubinsky, D. (2011) "Hierarchical Temporal Memory including HTM Cortical Learning Algorithms", Numenta Inc. White paper.
- [12] Hawkins, J. & Blakeslee, S. (2004) "On intelligence", 1st ed. New York: Times Books.
- [13] Hawkins, J., George, D., & Niemasik, J. (2009), "Sequence memory for prediction, inference and behaviour", *Philosophical Transactions of the Royal Society B: Biological Sciences*, vol. 364, pp. 1203-1209
- [14] Hubel, D. H., & Wiesel, T. N. (1962), Receptive fields, binocular interaction and functional architecture in the cat's visual cortex", *Journal of Physiology*, 160 (1), 106-154.
- [15] Muller, J. (1993), "Objetivos de mejoramiento genético para rumiantes menores", INTA EEA Bariloche, Comunicación Interna, PA 238.
- [16] Programa Nacional Fibras Animales, Documento Base actualizado a noviembre de 2011. INTA, (2011)
- [17] Resko, B, Roka, A. and Baranyi, P. (2005) "Visual Cortex Inspired Intelligent Contour Detection," *Journal of Advanced Computational Intelligence and Intelligent Informatics*, vol. 10, no. 5, pp. 761-768.
- [18] SUPPRAD, Programa de Sustentabilidad Productiva de Pequeños Rumiantes en Áreas Desfavorecidas, UCC, Facultad de Veterinaria, 2013
- [19] Thorpe S, Fize D, Marlot C (1996) "Speed of processing in the human visual system". *Nature* 381: 520-522.