

250

UNIVERSIDAD NACIONAL DEL CALLAO




FACULTAD DE INGENIERÍA ELÉCTRICA Y ELECTRÓNICA

INSTITUTO DE INVESTIGACION DE LA FACULTAD DE

INGENIERÍA ELÉCTRICA Y ELECTRÓNICA



ENE 2015



INFORME FINAL DEL PROYECTO DE INVESTIGACION "DISEÑO DE UN MODELO NEURONAL PARA EL RECONOCIMIENTO DE IMÁGENES Y COLOR"

AUTOR: WILBERT CHÁVEZ IRAZÁBAL

(PERIODO DE EJECUCION DEL 01/09/2013 AL 31/08/2014)

(RESOLUCIÓN RECTORAL N° 895-2013-R)

CALLAO-2014

I INDICE

I.- INDICE.....	Pág. 1
II.- RESUMEN Y ABSTRACT.....	Pág. 2
III.- INTRODUCCIÓN.....	Pág. 4
3.1 Planeamiento del problema de investigación.....	Pág. 4
3.2 Objetivos.....	Pág. 4
3.2.1. Alcances.....	Pág. 4
3.3 Importancia y justificación de la Investigación.....	Pág. 5
3.4 Formulación de la Hipótesis.....	Pág. 5
IV.- MARCO TEORICO.....	Pág. 6
4.1 Segmentación de Imágenes.....	Pág. 6
4.1.1 Métodos de segmentación de imágenes.....	Pág. 7
4.1.1.1 Segmentación basada en regiones.....	Pág. 7
4.1.1.2 Segmentación basada en bordes.....	Pág. 9
4.1.1.3 Segmentación basada en agrupaciones de píxeles o clustering.....	Pág. 12
4.1.1.4 Modelo Visual de la segmentación perceptual: BCS/FCS.....	Pág. 13
4.2 Reconocimiento de patrones.....	Pág. 18
4.2.1 La Teoría de resonancia adaptativa.....	Pág. 20
4.2.1.1 Predictor adaptivo mínimo.....	Pág. 22
4.2.1.2 Características de ART.....	Pág. 24
4.2.1.3 Comparación del Reconocimiento de patrones clásico con ART.....	Pág. 25
4.2.2 Fuzzy ART.....	Pág. 26
4.2.3 Fuzzy ARTMAP.....	Pág. 30
V.- MATERIALES Y MÉTODOS.....	Pág. 34
5.1 Modelo dinámico propuesto.....	Pág. 35
5.1.1 Sistema de Color Oponente (COS).....	Pág. 36
5.1.2 Sistema Cromático Segmentador.....	Pág. 38
5.2 Implementación de la arquitectura.....	Pág. 40
5.2.1 Herramienta BCS FCS Color.....	Pág. 40
5.2.2 Detalles de la Implementación.....	Pág. 40
5.2.2.1 La Herramienta BCS FCS Color. Presentación y manual de usuario.....	Pág. 41
VI.- RESULTADOS.....	Pág. 56
VII.- DISCUSIÓN.....	Pág. 63
VIII.- REFERENCIAS.....	Pág. 67
IX.- APÉNDICE.....	Pág. 72
X.- ANEXO.....	Pág. 74



II RESUMEN y ABSTRACT

Resumen

En este trabajo proyecto que se presenta tiene como finalidad el diseñar un Modelo Neuronal para el Reconocimiento de Imágenes y Color. El modelo neuronal es dinámico y multi-escala para la segmentación de imágenes en color. Basado en aspectos biológicos presentes en el sistema visual humano, el modelo combina información cromática y textural para segmentar las imágenes de forma coherente. La arquitectura del modelo diseñado está constituida por dos módulos principales: el Sistema de Color Oponente (*Colour Opponent System*, COS) y el Sistema de Segmentación Cromática (*Chromatic Segmentation System*, CSS). El módulo COS transforma la señal cromática de entrada RGB en las longitudes de onda de activación de los conos, fotorreceptores presentes en la retina de los mamíferos: longitud de onda larga (L), media (M) y corta (S), y en la señal de luminancia. Posteriormente, los dos tipos de células presentes en el módulo COS se encargan de componer procesos oponentes utilizando estas nuevas señales, generando el canal de luminancia y los canales L-M, S-(L+M). El módulo CSS incorpora los procesos de extracción de contornos y posterior difusión para lograr el resaltado coherente de las regiones de la imagen. La estructura del módulo CSS se basa en el modelo neuronal BCS/FCS, pero ampliado para permitir el procesamiento de los estímulos de color con el objetivo de conseguir una arquitectura de propósito general para la segmentación de imágenes con aplicaciones en visión artificial y reconocimiento de objetos. Las simulaciones realizadas muestran el potencial de estas características, los buenos resultados obtenidos y la robustez de la arquitectura al presentar imágenes de entrada con diferentes niveles de ruido. Para el módulo de reconocimiento se utiliza una estructura de Red Neuronal Fuzzy ARTMAP. Se procesaron imágenes partiendo de las imágenes patrones.

Summary

This paper presents project that aims to design a Neuronal Model for Image Recognition and Color. The neural model is dynamic and multi-scale image segmentation in color. Based on biological aspects in the human visual system, the model combines color and textural information to segment images consistently. The designed architecture model consists of two main modules: the Colour Opponent System (Colour Opponent System, COS) and the Chromatic Segmentation System (Chromatic Segmentation System, CSS). The COS module transforms the RGB color input signal wavelengths activation cones, photoreceptors in the retina of mammals: long wavelength (L), medium (M) and short (S) and the luminance signal. Subsequently, the two types of cells present in the COS module is responsible for composing opponent processes using these new signals, generating the luminance channel and the LM, S channels (L + M). The CSS module incorporates the processes of contour extraction and subsequent diffusion to achieve consistent highlight regions of the image. The structure of the CSS module is based on the neural model BCS / FCS, but extended to allow the processing of color stimuli in order to get general purpose architecture for image segmentation with applications in computer vision and object recognition. Simulations show the potential of these features, good performance and robustness of architecture by presenting input images with different noise levels. For recognition module structure Fuzzy ARTMAP neural network is used. Images were processed according to the images patterns.

PALABRAS CLAVES: Reconocimiento, Segmentador, Clasificador, Red Fuzzy, Color.

III INTRODUCCION

3.1 Planteamiento del problema de investigación:

Al realizar el estudio del reconocimiento de Imágenes de Color y Textura, mediante una arquitectura Neuronal Multi escala nos planteamos las siguientes preguntas:

¿Cómo influyen los clasificadores en el proceso de reconocimiento?

¿Cómo influye la segmentación en el proceso de reconocimiento de Imágenes?

3.2 Objetivos:

a. Objetivo General

El presente trabajo tiene como objetivo el diseño de un modelo Neuronal para el reconocimiento de Imágenes y Color, que nos ayudaran a distinguir y optimizar la selección de los objetos con mayor fiabilidad.

b. Objetivo Especifico

- Estudiar el problema de segmentación de las señales.
- Estudiar el principio de funcionamiento de una red neuronal ARTMAP y la respuesta de los filtros orientados y difusiones cromáticas.

3.2.2 Alcances

a. El trabajo de investigación es de tipo teórico- práctico aplicativo.

b. El sector que será beneficiado es el de Telecomunicaciones y a los alumnos. Las Telecomunicaciones porque forma parte de los sistemas de procesamiento de señales aplicados a usos industriales, y los alumnos porque ellos podrán tomar como ejemplo este trabajo de investigación para enriquecer sus

conocimientos y crear nuevas opciones para optimizar el uso del módulo desarrollado.

3.3 Importancia y justificación de la Investigación

- La importancia del presente trabajo se da por el desarrollo de una aplicación capaz de conseguir mejora la capacidad de visualización de objetos.
- Es de sumo valor tecnológico este proyecto, pues contribuimos a dar solución a mejorar los recursos de visión artificial aplicados a la industria.

3.4 Formulación de la Hipótesis

Partimos de la HIPÓTESIS que la implementación del diseño mejora la fiabilidad del reconocimiento de imágenes y color.

En tal sentido, las variables que se operacionalizarán serán las siguientes:

Variable Independiente:

Diseño de un Modelo Neuronal.

Variable Dependiente:

La fiabilidad del reconocimiento de imágenes y color.



IV MARCO TEORICO

4.1.- Segmentación de Imágenes.

El proceso de segmentación consiste en extraer las regiones que componen la imagen, facilitando así el reconocimiento de las mismas.

El sistema visual segmenta las señales oponentes de color en regiones que están separadas por contornos o límites perceptuales. La interpretación de la escena en etapas superiores del sistema visual, depende en gran medida de los resultados de la segmentación. Por ello, la segmentación es una etapa fundamental en el procesamiento de la información visual. Los límites perceptuales están definidos por discontinuidades lumínicas, por diferencias estadísticas en cualidades texturales tales como orientación, forma, densidad o color [Beck-83][Julesz-81], o por contornos ilusorios (piénsese en el cuadrado de Kanizsa).

La segmentación de la **escena en el sistema visual** se produce rápidamente a través de todas las regiones de la escena. Este modo de comportamiento se denomina *preatencional*. Es decir, este modo de actuación describe los límites de las regiones de una manera consistente cuando los tiempos de exposición del estímulo son muy pequeños (aproximadamente de una a dos décimas de segundo). Las características más significativas de la segmentación preatencional son las siguientes [Julesz-87]:

- Este modo preatencional es un proceso altamente paralelo.
- La segmentación se produce de forma instantánea.
- Se extiende totalmente sobre el campo visual.
- La segmentación no depende del número de regiones existentes.
- Esta visión preatentiva se presenta en la discriminación de texturas.

Las características locales de una escena, tales como contornos, orientaciones, y contrastes, son perceptualmente ambiguas. Sin embargo, un observador puede agrupar rápidamente combinaciones de estas características para separar los objetos presentes en la escena. Es decir, el observador agrupa las características locales según unas características emergentes que dependen de la estructura de los elementos texturales en la escena [Grossberg-85a]. Por lo tanto, la segmentación preatencional está controlada por las características emergentes de la escena.

La arquitectura neuronal propuesta en este trabajo de investigación desarrolla una extensión del modelo visual BCS/FCS para poder procesar información de color, manteniendo el comportamiento perceptual del modelo original.

4.1.1- Métodos de segmentación de imágenes

Los algoritmos de segmentación generalmente están basados en dos criterios importantes a considerar: uno es la homogeneidad de la región y otro es la discontinuidad entre regiones disjuntas adyacentes. Aunque hay una amplia variedad de técnicas de interpretación de imágenes que están bien tratadas en [Haralick-93], es difícil satisfacer todas las propiedades para el conjunto óptimo de regiones segmentadas.

4.1.1.1- Segmentación basada en regiones

Las segmentaciones basadas en regiones parten de la idea de que la región a segmentar es una región homogénea desde algún punto de vista. Existe un criterio de homogeneidad H que cumple cada región individualmente, pero que no se cumple en el caso de la unión de dos regiones.

La umbralización con histogramas se podría clasificar dentro de este grupo de técnicas. Es una de las técnicas más sencillas y, tal vez por ello, más utilizada en la segmentación de imágenes en general. Consiste en la

determinación de unos umbrales que delimitan el rango de intensidades que caracterizan y discriminan los distintos objetos de la imagen. Algunas de las técnicas más conocidas son:

- **Umbralización bimodal:** Se calcula el histograma, se suaviza y se calcula el umbral como el valor valle entre las dos agrupaciones de datos (normalmente fondo y objeto).
- **Umbralización por porcentajes (P-Tile):** Si se tiene información a priori del número de píxeles del objeto, el umbral se calcula como el valor que hace que el objeto tenga dicho número o su mayor aproximación.
- **Umbralización por coincidencia de contornos:** Se calcula el umbral que hace que coincidan los contornos naturales de la imagen con los producidos por la umbralización.
- **Método de Otsu:** Este método busca el umbral que minimiza la varianza acumulada de cada objeto por separado, obteniendo buenos resultados. Sin embargo, este método usa una búsqueda exhaustiva para evaluar el criterio para maximizar la varianza entre clases, lo que hace que aumente mucho el tiempo al incrementarse el número de clases [Nobuyuki-79].

El crecimiento de regiones basado en semilla es un algoritmo de segmentación con una estrategia abajo-arriba. Fue desarrollado por Yakimovsky en [Yakimovsky-76]. En este algoritmo, se coge un punto (semilla) dentro de la región de interés y se van añadiendo píxeles adyacentes mientras satisfagan la propiedad de homogeneidad seleccionada. La salida de dicho algoritmo sería una única región simple y conectada. Para distinguir N regiones en una imagen se deben coger N puntos semilla y repetir el algoritmo N veces. La Figura N°4.1 muestra un ejemplo del algoritmo sobre una imagen médica.




Figura N° 4.1: Crecimiento de regiones basado en semilla.

La segmentación división-fusión recursiva (*split-merge*) es una aproximación arriba-abajo desarrollada en [Horowitz-76]. Al contrario que el crecimiento de regiones a partir de la semilla, en este algoritmo se comienza considerando la imagen original como una única región. Si la región no es uniforme en relación con las métricas consideradas, la región se divide en sub-regiones. Un efecto típico de este tipo de algoritmo, es que la imagen es habitualmente sobresegmentada, al dividir regiones en otras sin considerar si con menos regiones habría sido suficiente. El orden en el que se realiza la fusión de regiones adyacentes es un aspecto crítico en este modelo. Existen dos alternativas, la primera de ellas consisten en buscar sobre todo el espacio de regiones adyacentes y fusionar con aquella que produzca una región final más uniforme. Como se puede deducir, el coste computacional de esta alternativa es muy elevado. Una alternativa más rápida es realizar un número de pasos limitado sobre la lista de regiones adyacentes y fusionar cualquiera de ellas que cumplan los requisitos de homogeneidad.

4.1.1.2- Segmentación basada en bordes

En este tipo de segmentación se parte de la hipótesis de que las regiones a segmentar están separadas por una frontera claramente identificable. Lo que se busca es detectar esas regiones 'frontera' y a partir de ellas definir las distintas regiones. La mayor dificultad a la hora de detectar bordes es distinguir los bordes de lo que no son bordes.

Si dos objetos con diferentes colores son adyacentes en una imagen, entonces habrá un cambio importante en la percepción del color cuando

Handwritten signature or mark.

nos movemos de un objeto hacia el otro. Entonces, la detección de los bordes se puede realizar buscando discontinuidades de color en la imagen utilizando la función gradiente bidimensional teniendo en cuenta el carácter bidimensional de las imágenes digitales [Roberts-65].

Uno de los problemas de la detección basada en gradientes es que no todas las fronteras presentan contrastes muy marcados. Como el gradiente se compone de derivadas parciales de primer orden, el operador Laplaciano (segunda derivada) indicará el punto que ha sido máximo en la detección de un contorno [Marr-80].

Existen diversas máscaras espaciales que permiten calcular el gradiente o derivada discreta de la imagen [Pratt-01]. El filtro de Roberts [Roberts-65] es de tamaño 2x2, siendo más rápido pero menos preciso. Los filtrados de Prewitt [Prewitt-70] y Sobel [Sobel-78] emplean tres máscaras de 3x3, una para cada dirección espacial: horizontal, vertical y diagonal. El uso de máscaras en distintas direcciones permitiría calcular la dirección del gradiente además de su valor.

Un proceso más sencillo y cuyo resultado es similar al del Laplaciano es el denominado DOG (*difference of gaussians*). Consiste simplemente en filtrar la imagen sucesivamente con gaussianas con valores crecientes de varianzas, y obtener la diferencia entre ellas.

Como ejemplo de detector de bordes más complejo se puede estudiar el detector de bordes de Canny(ver Figura N°4.2) [Canny-86]. Para definir el proceso, Canny partió de dos criterios de calidad de la detección de bordes:

- Se quieren detectar todos los bordes reales y el mínimo número de puntos que no correspondan a bordes.
- Se quiere que la localización de los puntos detectados sea lo más precisa posible.



En este detector, en primer lugar se filtra la imagen con una máscara Gaussiana, y se calcula la dirección de los bordes. A continuación se eliminan los máximos el gradiente que no estén en la dirección adecuada (perpendicular a los contornos obtenidos), y finalmente, se umbraliza la imagen de bordes obtenida. Se puede modificar las escalas de trabajo variando el valor de σ (desviación típica de la Gaussiana), así hay objetos pequeños que no aparecen en la segmentación, ya que se han filtrado en el primer paso.



Figura N°4.2: Detector de bordes de Canny. A la izquierda la imagen original, en el centro el resultado para $\sigma=1$, en la derecha para $\sigma=5$.

Otro método clásico e interesante, por ser algo más específico es la transformada de Hough [Duda-73]. Es un algoritmo orientado a detectar contornos con formas geométricas determinadas (rectas, circunferencias, etc.). La detección de rectas, por ejemplo, se basa en la ecuación de la recta en el plano. Por cada punto de gradiente de la imagen aumentamos el valor de un punto en un espacio equivalente de parámetros de una recta. De este modo, las zonas en el nuevo espacio de alta intensidad corresponden a rectas presentes en la imagen original. Del mismo modo, podríamos detectar cualquier forma describible con su ecuación geométrica.

Una vez que los píxeles que forman los contornos han sido identificados, es normal unir dichos puntos para formar contornos de objetos cerrados. Esto puede realizarse avanzando un píxel en el sentido de las agujas del reloj (o en el sentido contrario) alrededor del perímetro del objeto moviéndonos desde un punto del borde al siguiente. Aunque esto pueda

sonar trivial, la decisión de a qué punto saltar en cada momento puede ser realmente complicada debido a la presencia de varios puntos presentando elevada actividad de borde. La respuesta a esta pregunta podría ser dependiente de los pasos previos pero a veces la presencia de numerosos posibles píxeles dificulta la elección. Existen soluciones matriciales para este problema que establecen órdenes preseleccionados en función de parámetros dependientes del paso anterior.

4.1.1.3-Segmentación basada en agrupamientos de píxeles o clustering

Las técnicas de agrupamiento clasifican los píxeles estadísticamente, sin tener en cuenta su situación espacial. Es decir, no empleamos información de regiones o de bordes, sólo información de intensidad de cada punto. La forma más sencilla es aquella en que definimos a priori el número de clases en que queremos clasificar los píxeles, y seleccionamos ciertas muestras de cada clase. Esta es la clase de técnicas denominadas supervisadas. Las técnicas no supervisadas son totalmente automáticas y el número de clases se escoge a lo largo del proceso.

El *clustering* permite hacer uso de diversos valores en cada píxel, por ejemplo si tenemos una imagen en color o varias imágenes de una misma escena adquiridas con parámetros distintos. A partir de los distintos valores o características de cada punto, se realiza una clasificación estadística multivariable.

Para la clasificación se pueden usar diversas características de cada punto. La intensidad o valores cromáticos en una o más imágenes, características que se pueden obtener mediante algunos filtrados, etc.

Existen diversos algoritmos de clasificación:

- *K-Nearest Neighbour*, KNN [MacQueen-67]: mayoría de los k vecinos

- *Fuzzy C-Means*, FCM [Dunn-73]: número de clases prefijado
- Clasificación jerárquica ascendente: tantas clases como píxeles
- Clasificación jerárquica descendente: una sola clase para empezar

En general, los algoritmos de clustering son métodos algo lentos.

4.1.1.4- Modelo Visual de la segmentación perceptual: BCS/FCS

La teoría BCS/FCS fue desarrollado por Stephen Grossberg y sus colaboradores [Grossberg-85a] [Grossberg-87a] [Grossberg-85b] [Grossberg-88] [Grossberg-87b] para modelar el proceso de segmentación perceptual monocromática. El modelo está constituido por la interacción de dos sistemas denominados *Boundary Contour System* (BCS) y *Feature Contour System* (FCS). La primera idea fundamental que introduce este modelo radica en la distinción entre estos dos sistemas. Estos dos sistemas extraen dos tipos de señales de contornos en las primeras etapas de procesamiento. Estas señales se denominan señales de contornos de límite y señales de contornos de características, *boundary contour* y *feature contour* en la teoría original. En imágenes texturadas, las primeras señales contienen la información textural, mientras que las segundas señales son sensibles a las diferencias de luminancia. Las señales de contornos de límite se transforman en una estructura coherente de contornos reales e ilusorios a través de sucesivas etapas de procesamiento dentro del sistema BCS. Esta estructura de contornos surge del agrupamiento perceptual según las características emergentes de la escena. Por su parte, las señales de contornos de características inician procesos de rellenado, denominados *filling-in* en la teoría original, dentro del sistema FCS. En estos procesos el color o matiz de gris se expande en todas las direcciones hasta encontrar una señal fuerte de contorno procedente del sistema BCS. En definitiva, el sistema BCS genera agrupamientos perceptuales para definir dominios perceptuales adecuados para contener la expansión de características.

Los aspectos básicos que diferencian este modelo del resto de los métodos y modelos de segmentación son los siguientes:

- Proceso de agrupamiento según características emergentes
- Extracción de contornos ilusorios
- Eliminación de los efectos producidos por las variaciones en las condiciones lumínicas de la escena (en la teoría original se denomina *discounting the illuminant*).
- Proceso de rellenado de zonas limitadas por contornos reales e ilusorios.

Tomando el ejemplo mostrado en la Figura N°4.3 con el fin de clarificar los conceptos de característica emergente y agrupamiento perceptual. En esta figura se incluyen dos muestras texturizadas generadas por una distribución espacial aleatoria de pequeñas barras horizontales. En la muestra superior existe un alineamiento vertical de barras en su centro, mientras que en la muestra inferior el alineamiento central es horizontal. Las barras están igualmente distribuidas en las dos muestras, salvo aquellas que forman los alineamientos. Al observar la muestra superior, notamos una sensación de verticalidad producida por el alineamiento central. Existe un agrupamiento vertical que induce a percibir dos zonas separadas por una franja vertical generada por las barras alineadas. Sin embargo, la percepción de la figura inferior nos hace separar la muestra en una zona superior y una zona inferior, separadas por una línea horizontal. En definitiva, segmentamos perceptualmente cada muestra en dos zonas según el agrupamiento que se produce. Es importante destacar que los agrupamientos vienen dados por la generación de contornos ilusorios que unen las barras según la dirección emergente. Esto hace que las barras del alineamiento se perciban como un conjunto.

La horizontalidad y la verticalidad son las características emergentes de las muestras superior e inferior respectivamente. Por otro lado, el agrupamiento perceptual hace que se unan las barras siguiendo la

dirección dada por la característica emergente. Con este ejemplo, mostramos la importancia del agrupamiento de elementos texturales según las características emergentes para segmentar perceptualmente la escena. Así como, la necesidad imprescindible de extraer los contornos ilusorios.




Figura N°4.3: Las dos figuras muestran una misma distribución aleatoria de pequeñas barras horizontales.

En la distribución que se muestra en la Figura N°4.3, se ha incluido un alineamiento vertical, figura superior, y un alineamiento horizontal, figura inferior. Según el tipo de alineamiento se introduce un agrupamiento diferente: vertical en la figura superior y horizontal en la figura inferior.

Los contornos ilusorios tienen mucha importancia dentro de este modelo. Estos contornos son producto de los mecanismos de la percepción, y no corresponden a diferencias de luminancias o de características texturales en la escena. Este modelo sugiere que los contornos ilusorios pueden tener un efecto importante en los procesos de agrupamiento perceptual y reconocimiento de objetos. Otro ejemplo donde se muestra la importancia de los contornos ilusorios en la percepción es el fenómeno que se produce en el conocido cuadrado de Kanizsa, mostrado en la Figura N°4.4 en esta imagen se percibe un cuadrado cuyo interior posee un matiz de mayor intensidad que el matiz del exterior. Por lo tanto, en la percepción se han generado los contornos del cuadrado y se ha producido un rellenado del interior del cuadrado de mayor intensidad que el exterior del cuadrado vienen inducidos por las prolongaciones de los contornos lineales reales de los sectores circulares. Estas prolongaciones

A handwritten mark or signature in the bottom right corner of the page.

se producen por procesos que completan los contornos lineales, cuyos extremos están determinados por los contornos lineales reales de los sectores circulares.

Por otra parte, podemos observar la Figura N°4.4, que no somos capaces de distinguir qué partes de la percepción del cuadrado derivan directamente de las señales de la retina y cuales proceden de completar contornos o de procesos de rellenado. Ejemplos de este tipo, sugieren que tanto las figuras "reales" como "ilusorias" son generadas por los mismos mecanismos perceptuales, y además, sugieren el motivo de la importancia de los contornos ilusorios en los procesos de agrupamiento perceptual [Grossberg-85a].




Figura N°4.4: Cuadrado de Kanizsa. En esta figura, podemos percibir los contornos del cuadrado (contornos ilusorios) aunque estos no sean consecuencia de una diferencia de luminosidades. Estos contornos ilusorios vienen inducidos por las prolongaciones de los contornos lineales reales en los sectores circulares al coincidir su orientación.

Por lo general, el mundo real es observado bajo condiciones lumínicas no homogéneas. Es decir, una zona de un determinado color en la escena puede estar iluminada de forma variable. Esto hace que las luminancias que se proyectan en la retina puedan producir confusión en la percepción del color de esa zona. Es conocido que el cerebro produce mecanismos que aminoran este efecto. Varios experimentos utilizando cuadros formados por polígonos de diferentes colores y observados bajo diferentes condiciones lumínicas, han mostrado que los colores del

interior de los polígonos eran suprimidos. La percepción final era formada a partir de los contrastes cromáticos entre los límites de los polígonos [Grossberg-85a] [Grossberg-85b]. Es evidente que este efecto debe estar acompañado de un rellenado entre límites con el matiz resultante del contraste cromático.




Figura N°4.5: A) Imagen formada por cinco bandas cuyo perfil de luminancias a través de la línea discontinua viene descrito en B). Ésta linealidad de luminancias en cada banda puede ser el resultado de iluminar la escena desde el lado derecho. C) Perfil de luminosidades percibidas.

La imagen de la Figura N°4.5 A) está compuesta de cinco bandas cuyo perfil de luminancias a través de la línea discontinua podría venir dado por el perfil mostrado en la Figura N°4.5 B). La distribución de luminancias simula el efecto que se produciría si la escena compuesta de cinco bandas de luminancia constante se iluminará mediante una fuente de luz situada en el lado derecho de la escena. Observaciones en psicología perceptual muestran que la percepción de la escena en tales situaciones no coincide con la distribución de luminancias. Más bien, la percepción de esta escena viene descrita por el perfil de tramos constantes reflejado en la Figura N°4.5 C). Luego, el sistema visual pone en juego determinados mecanismos que eliminan la variación lineal de la luminancia en cada banda y rellenan cada banda con el matiz resultante del contraste en los límites entre bandas. Grossberg et al, [Grossberg-88] han simulado las

respuestas del modelo BCS/FCS en un número importante de situaciones de iluminación variable de escenas. En estas simulaciones puede observarse que este modelo posee un comportamiento acorde con la percepción visual.

Estos mecanismos de extracción de contornos ilusorios, relleno del interior de zonas limitadas por contornos reales e ilusorios y generación de agrupamientos según las características emergentes de la escena, son la base del modelo visual BCS/FCS.

4.2.- Reconocimiento de patrones.

Las técnicas de reconocimiento de patrones permiten clasificar o agrupar los objetos en base a características similares. Clasificar significa asociar a clases (prototipos) una serie de elementos. Esta asociación se realiza en base a las propiedades de los objetos.

El reconocimiento es una etapa fundamental en análisis de imágenes, a partir de las características extraídas de las regiones resultantes de la segmentación de una imagen se pueden reconocer los objetos presentes en ella.

Un clasificador es un algoritmo que permite definir un modelo para cada clase, de tal forma que la clase a la que pertenece un elemento se puede calcular a partir de los valores de los datos que definen el elemento. Por lo tanto, de forma más práctica, el objetivo de un clasificador es asignar de forma lo más precisa posible una clase a nuevos elementos previamente no estudiados. Se suele utilizar indistintamente los términos aprendizaje y entrenamiento para referirse al proceso de construcción del clasificador. El aprendizaje puede realizarse de forma supervisada o de forma no supervisada.

El método neuronal elegido para desarrollar el módulo de reconocimiento de la arquitectura propuesta en este trabajo es las redes Fuzzy ART y Fuzzy ARTMAP.



Las redes multicapa introducen el concepto de la capa oculta de neuronas, entre las dos capas de entrada y salida. Esta nueva capa permite el uso de una serie de pesos no controlables directamente por el entorno. El algoritmo de propagación hacia atrás, se refiere al aprendizaje supervisado, donde la salida de la red se compara con la salida deseada. Propagando el error hacia las capas ocultas, los pesos se vuelven a adaptar, llegando al final a un mínimo de una función de error o energía. El éxito de este modelo tiene sus fundamentos en su capacidad de aproximar cualquier función no lineal, en la sencillez y la familiaridad del algoritmo de propagación hacia atrás, y en el momento oportuno de su propuesta. Actualmente, las redes multicapa ocupan la inmensa mayoría de las arquitecturas neuronales propuestas en los distintos campos. Deberíamos mencionar las principales desventajas de las redes multicapa que usan el algoritmo de propagación hacia atrás:

- La idea de propagación del error hacia atrás no tiene ningún fundamento neurobiológico, aunque Rumelhart propuso una variación que sostenía cierta explicación biológica.
- No está garantizada la convergencia del algoritmo a un mínimo global.
- Se necesita un número enorme de iteraciones hasta llegar al punto estable.
- No se conoce la estructura de la red a-priori (número de nodos, número de nodos por capa o función de salida).

Se han propuesto numerosas arquitecturas y variaciones sobre el modelo básico de la red multicapa, todas ellas siguiendo el modelo de aprendizaje supervisado. Por otro lado, se han propuesto varios modelos que siguen el aprendizaje no supervisado, que corresponde al concepto de agrupamiento que hemos visto anteriormente. Muchos de los modelos de este tipo tienen una estrecha relación con el funcionamiento natural, ofreciendo muchas perspectivas de desarrollo.

Entre otros tendríamos que destacar el mapa auto-organizativo de Kohonen [Kohonen-84], el Neocognitron, modelo propuesto por Fukushima [Fukushima-80] y la red neuronal de "counterpropagation" de Hecht-Nielsen [Hecht Nielsen-87], así como la Teoría de Resonancia Adaptativa (ART) de S. Grossberg y G. Carpenter, sobre la que se basa la fase de reconocimiento propuesta en la arquitectura desarrollada en la presente tesis. Por la importancia de esta teoría para nuestra arquitectura, en las siguientes secciones se abordará más detalladamente.

Los modelos de redes neuronales se han aplicado hasta ahora principalmente en problemas de reconocimiento de patrones, y de memorias asociativas, mientras que aplicaciones más importantes han ido apareciendo sobre diversos temas, como control no lineal, robótica, predicción económica, etc. Aunque se observa un claro solapamiento entre el reconocimiento de patrones clásico y las redes neuronales artificiales, creemos que los modelos neuronales se pueden aplicar en diversos campos, pero siempre considerando las aproximaciones clásicas.

4.2.1 - La teoría de resonancia adaptativa (ART)

Es un modelo de red neuronal artificial que basa su funcionamiento en la manera en que el cerebro procesa información y que describe una serie de modelos de redes neuronales que utilizando métodos de aprendizaje supervisado y no supervisado abordan problemas tales como el reconocimiento y la predicción de patrones. El modelo ART soluciona el dilema de la estabilidad y plasticidad del aprendizaje mediante un mecanismo de realimentación entre las neuronas competitivas de la capa de salida.

Los dos dilemas, que se describen a continuación, aparecen constantemente en los módulos ART:

- **Dilema de elasticidad-plasticidad.** ¿Cómo puede el sistema adaptativo de un organismo ser suficientemente estable para

resistir fluctuaciones del entorno incapaces de alterar su comportamiento, siendo al mismo tiempo suficientemente flexible para cambiar rápidamente respondiendo a aquellas demandas del entorno capaces de alterar su comportamiento? En particular, ¿cómo puede el sistema preservar el conocimiento aprendido previamente mientras continúa aprendiendo?

- **Dilema de ruido-saturación.** Hay que tener en cuenta que las señales de nivel relativamente bajo se consideran ruido, mientras que una neurona lleva asociado un nivel de saturación para señales de entrada relativamente grandes. Por eso se plantea el siguiente dilema: ¿cómo puede el sistema ser sensible a entradas pequeñas sin amplificar el ruido o saturarse ante entradas grandes?

ART responde a los dos dilemas anteriores mediante los argumentos básicos siguientes:

- La percepción-cognición depende de un estado de actividad resonante del sistema. Este estado resonante se refiere al momento en el cual las características de un patrón externo y de un patrón esperado (aprendido anteriormente) coinciden de tal forma que la actividad en STM es reforzada. Los patrones esperados a través de su retroalimentación ayudan a estabilizar el código (codificación del patrón) contra los efectos erosivos de las fluctuaciones irrelevantes del entorno.
- El aprendizaje asociativo, donde dos patrones se asocian a través de condicionamiento, se considera como una predicción no estacionaria en tiempo real debido a que el tiempo entre dos estímulos a ser asociados puede variar arbitrariamente durante el aprendizaje. En este contexto, entendemos por tiempo real el hecho de que la predicción no está separada de la fase de aprendizaje.

- Se consideran interacciones no lineales entre la memoria a corto plazo (STM) y la de largo plazo (LTM).

Mientras que sus principios generales son:

- Algunas ecuaciones diferenciales básicas.
- Unos modelos generales articulados cada uno de ellos en módulos de redes neuronales.
- Unas arquitecturas que se diseñan a partir de los módulos generales.

4.2.1.1-Predictor adaptativo mínimo

El predictor adaptativo mínimo es una herramienta que permite explicar los fenómenos de cognición, memorias asociativas o condicionamiento, lo cual es un sistema cuya configuración mínima posee las siguientes características:

- Prestar atención y aprender sólo las características que ayudan a la predicción (rasgos predictivos).
- Cuando un patrón esperado es suficientemente distinto a la entrada, se produce una consecuencia inesperada. Esta redefine el conjunto de los rasgos predictivos potenciales.
- La redefinición se hace a través de la retroalimentación de un evento no específico.
- Todos los rasgos predictivos potenciales requieren un lugar de almacenamiento, desde el momento de su presentación hasta el momento de la retroalimentación. Este lugar es la memoria a corto plazo (STM).
- La búsqueda de la categoría se debe hacer de una manera paralela y exhaustiva.



- La no linealidad es imprescindible para una modelización completa del predictor, puesto que hay evidencia suficiente de ello en fenómenos psicológicos, como por ejemplo en la relación psicofísica entre la luminosidad y el juicio subjetivo. Al mismo tiempo hay gran evidencia sobre las características no locales y no estacionarias en el funcionamiento neuronal humano.

Los dilemas básicos (estabilidad-flexibilidad, ruido-saturación) posibilitan una respuesta y determinan unas características arquitectónicas del diseño de la red, como son:

- Inhibición lateral.
 - Camino TD (*top-down*): Proceso de arriba hacia abajo.
 - Camino BU (*bottom-up*): Proceso de abajo hacia arriba.
- **Inhibición lateral**

La inhibición lateral propia de los seres vivos, puede expresarse en la forma:

$$x_i = S_i - \sum_{j \neq i}^n [x_j - \Gamma_{ij}]^+ A_{ji} \dots\dots\dots 4.1$$

Donde x_i y x_j son las salidas de las neuronas i y j respectivamente, S_i es la entrada a la neurona i , Γ_{ji} es el umbral para la señal inhibitoria desde una neurona j a la neurona i , A_{ji} es el factor de peso para la señal inhibitoria desde la neurona i a la neurona j , y $[\]^+$ representa la rectificación de la señal definida como:

- **Ecuación de Hodgkin-Huxley y el dilema ruido-saturación**

La ecuación de Hodgkin-Huxley [Hodgkin-52] sobre las membranas de las neuronas (que les valió el premio Nobel) es:

$$C \frac{\partial V}{\partial t} = (V^+ - V)g^+ + (V^- - V)g^- + (V^p - V)g^p \dots\dots\dots 4.2$$

Donde V es el potencial de la membrana, V^+ , V^- , V^p representan los potenciales positivos, negativos y de decaimiento pasivo



respectivamente, y g^+ , g^- , g^p son las correspondientes entradas, plateó diferentes interrogantes en los siguientes aspectos:

- Excitación
- Inhibición
- Decaimiento pasivo
- El rango limitado de los nodos

Y dio lugar al modelo “*shunting*” (multiplicativo) de Grossberg, que explica el dilema de ruido saturación. En este modelo, las entradas de excitación, inhibición y decaimiento no se suman, sino que tienen un coeficiente (*gateshunt*) de tipo $V_{sat} - V_{actual}$.

4.2.1.2-Características de ART

Las principales características de la solución ART en comparación con otros sistemas neuronales son:

- Funcionamiento sin maestro (no supervisado) versus supervisado.
- Aprendizaje en tiempo real, en línea, versus fuera de línea (no en laboratorio).
- Se auto-estabiliza, independientemente de la secuencia o del número de entradas.
- Se puede ampliar sin límites matemáticos.
- El tiempo de búsqueda no aumenta para patrones ya familiares y con el tiempo se usa un acceso directo al código.
- El tipo (tamaño-discriminación) de las clases se puede regular: es decir, muchas o pocas clases, discriminación débil o fuerte.
- Se mantiene la generación de nuevas categorías, hasta agotar la capacidad de la memoria.

4.2.1.3- Comparación del Reconocimiento de patrones clásico con ART

El proceso clásico en el RP consiste en elegir a-priori las mejores características fuera de línea y, luego, ir clasificando según una definición de categoría (prototipo o límites de la clase).

En el ART el funcionamiento es:

“Las características conducen a un código según unos criterios (proceso BU) y el código genera un nuevo patrón de características según expectativas aprendidas (proceso TD).

El patrón inicial se compara con lo esperado y en el caso de emparejamiento insuficiente, se lanza una señal de rearme (*reset*), que inicia un nuevo ciclo hasta la estabilización” [Bullock-90, pág. 2-10].

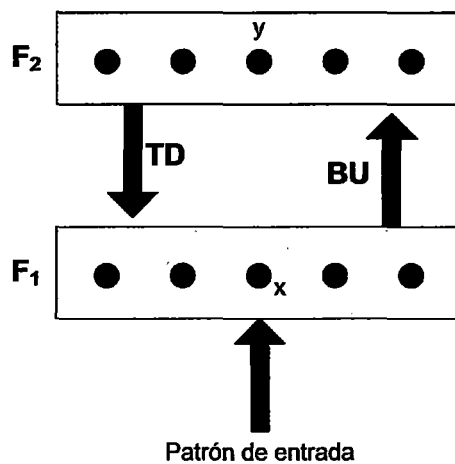


Figura N°4.6: Las dos capas de la arquitectura ART.

Siguiendo la Figura N°4.6, Y es el código en F_2 del patrón de actividades X , después de sintonizar el filtro de aprendizaje (correspondencia de muchos a uno), para el patrón de entrada. Para el código Y , el caso más simple es una red de elección: “el ganador lo coge todo”, a través de competición en F_2 . En el caso más general el código es distribuido en varios nodos del F_2 .

La regla más simple de modificación de los pesos w_{ij} es restando el decaimiento multiplicativo del producto de la regla Hebb.

En un sistema de clasificación autónoma, como es el filtro adaptativo BU, ocurren errores, porque en el mundo real las categorías no tienen unos límites bien definidos y también hay pocas características únicas.

La importancia de la utilización de detección y corrección de errores en las operaciones de codificación radica en la posibilidad de los inconvenientes siguientes:

- Acceso a corto plazo a acciones erróneas.
- Sobre-escritura errónea, a largo plazo, del nuevo aprendizaje sobre el viejo.

Para poder detectar el error internamente (sin necesidad de una retroalimentación de la salida y además antes de la selección de la respuesta), tiene que existir un lugar donde se puedan comparar el patrón de F_1 y el patrón esperado de F_2 y que pueda mediar el grado de emparejamiento.

4.2.2 Fuzzy ART

Fuzzy ART fue introducida por Carpenter, Grossberg y Rosen en 1991 [Carpenter-91]. Es una versión modificada del ART1, que es capaz de aceptar patrones de entrada analógicos fuzzy, como por ejemplo vectores cuyos componentes sean números reales entre 0 y 1. Fuzzy ART es una red neuronal no supervisada que dispone de aprendizaje incremental.

Una red Fuzzy ART está formada por dos capas de neuronas, la capa de entrada F_1 y la capa de salida F_2 que se puede observar en la Figura N°4.7. Ambas capas tienen un modelo de actividad esquematizado en la figura con barras verticales de altura variable. Las capas están completamente interconectadas de manera que cada neurona se conecta a cada neurona de la otra capa. Cada conexión está ponderada con un número entre 0 y 1.



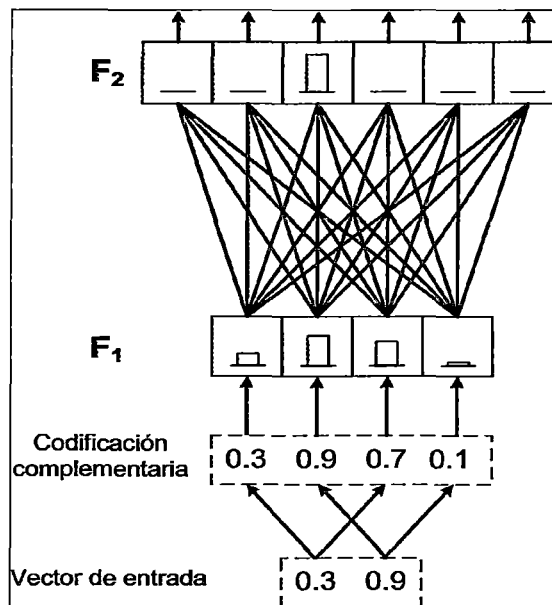


Figura N°4.7: Esquema de la red neuronal Fuzzy ART.

Una neurona de F_2 representa una categoría formada por la red y está caracterizada por su vector de pesos w_j (j es el índice de la neurona). El tamaño del vector de pesos es igual a la dimensión M de la capa F_1 . Inicialmente todos los componentes del vector de pesos son fijados a 1. Mientras que los pesos de una neurona no se modifiquen, se dice que 'no está comprometida' (*uncommitted*). Una vez que los pesos de la neurona se han modificado, se dice de esta neurona que 'está comprometida' (*committed*).

La red usa una forma de normalización llamada codificación complementaria. La operación consiste en tomar el vector de entrada y concatenarlo con su complementario. El vector resultante se presenta a la capa F_1 . Por tanto la dimensión M de la capa F_1 es el doble de la dimensión del vector de entrada. La codificación complementaria puede ser también desactivada.

Fuzzy ART aprende situando hiper cajas en el hiper espacio de $M/2$ dimensiones, siendo M el tamaño de la capa F_1 . Como se dijo anteriormente, cada neurona de la capa F_2 representa una categoría formada por la red, y esta categoría se define por una caja. La posición de

la caja en el espacio se codifica en el vector de pesos de la neurona. Debido a la codificación complementaria y al proceso de aprendizaje que se explicará más adelante, la primera mitad del vector de pesos memoriza una esquina de la caja (la más próxima al origen) y la otra mitad memoriza la esquina opuesta.

▪ **Entrenamiento**

Cuando un vector de entrada se presenta a la red, se pre procesa primeramente en su forma de codificación complementaria. El vector resultante, I , representa un punto en el espacio. El modelo de actividad de la capa F_1 se fija igual a I . La función de elección se evalúa entonces para cada neurona de F_2 . Esta función se define por:

$$T_j = \frac{|I \wedge w_j|}{\alpha + |w_j|} \dots\dots\dots(4.3)$$

Donde $||$ es la norma L1 del vector, por ejemplo la suma de sus componentes $(|p| \equiv \sum_{i=1}^M p_i)$, \wedge es el operador fuzzy AND $((p \wedge q)_i \equiv \min(p_i, q_i))$ y α es el parámetro de elección. El parámetro de elección α debe ser mayor que cero. Normalmente se elige cercano a cero para un buen funcionamiento [Carpenter-91, pág. 701]. Este parámetro asegura que cuando un punto está encerrado en más de una caja, la menor es la seleccionada. Éste es de hecho el objetivo de la función de elección: elegir la menor caja en la cual el punto está incluida. Se dice que un punto está en una caja cuando el vector de peso w_j correspondiente a esa caja es un subconjunto fuzzy del vector de entrada I . Si no existe dicha caja, se selecciona aquella que necesite expandirse menos para encerrar el punto o bien se crea una nueva caja, por ejemplo se elegiría la primera neurona que aún no haya sido modificada. Hacer notar que el tamaño de una caja se define como la suma de sus distancias en cada dimensión.

Una vez que una neurona es seleccionada (neurona ganadora), se evalúa un criterio de vigilancia. El criterio de vigilancia hace a la red seleccionar otra caja (neurona) si la elegida es demasiado grande. Así el parámetro de vigilancia ρ controla el tamaño máximo de las cajas. Matemáticamente el criterio de vigilancia es:

$$\frac{|\mathbf{I} \wedge \mathbf{w}_J|}{|\mathbf{I}|} \geq \rho \dots\dots\dots(4.4)$$

Donde J es el índice de la neurona ganadora en F_2 y ρ es el parámetro de vigilancia perteneciente al intervalo $[0,1]$. Si se cumple el criterio, Fuzzy ART aprende el vector de entrada, en caso contrario se selecciona la siguiente neurona con la función de elección más alta y se vuelve a evaluar el criterio de vigilancia. Estos dos pasos se repiten hasta que el criterio de vigilancia se cumpla. En ese momento, se dice que la red está en resonancia. Todos los componentes del modelo de actividad de F_2 , que es también el vector de salida de Fuzzy ART, se ponen a 0 excepto para el índice de la neurona ganadora que se pone a 1.

Cuando Fuzzy ART entra en resonancia, se procede al aprendizaje del vector de entrada I modificando el vector de pesos w_J de la neurona de la siguiente manera:

$$\mathbf{w}_J = \beta(\mathbf{I} \wedge \mathbf{w}_J) + (1-\beta)\mathbf{w}_J \dots\dots\dots(4.5)$$

Aquí, J es el índice de la neurona ganadora y $\beta \in [0,1]$ es la tasa de aprendizaje. Cuando $\beta=1$, estamos en el caso de aprendizaje rápido. Hay que hacer notar que los pesos no se incrementan con el tiempo, lo cual significa que una caja nunca puede encoger, sólo expandirse. Con aprendizaje rápido la última ecuación implica que la caja asociada con la neurona aumenta lo justo para incluir el punto representado por el vector de entrada. Si β es menor que 1, la caja se expandirá hacia el punto, siendo su expansión directamente proporcional al tamaño de β . Cuando se fija $\beta < 1$, estamos en lo que se denomina la opción 'rápida disposición,

recodificación lenta' (*fast-commit slow-recode*). Esta opción consiste en poner $\beta=1$ cuando la neurona aún no ha sido modificada y utilizar el valor real de $\beta (<1)$ después de que ésta haya sido modificada.

▪ Clasificación

El proceso de clasificación es muy similar al proceso de entrenamiento. Se realiza la etapa de elección y la de criterio de vigilancia. Sin embargo durante este proceso se bloquea el entrenamiento. Esto es interesante porque si ejecutamos la etapa de clasificación sobre un sistema que puede hacer procesamiento en paralelo podemos realizar la clasificación en paralelo ya que las categorías del sistema no son modificadas en este proceso, con la consiguiente ganancia en rendimiento temporal que esto conlleva.

4.2.3- Fuzzy ARTMAP

El modelo Fuzzy ARTMAP, introducido por Carpenter *et al.* [Carpenter-92], es una red supervisada compuesta por dos redes Fuzzy ART. Éstas se suelen identificar como ARTa y ARTb. Los parámetros de ambas redes se denotan con los subíndices *a* y *b* respectivamente. Ambas redes Fuzzy ART están interconectadas por un mapa de conexiones, interART, entre las capas F_2 de ARTa y ARTb. Estas conexiones están ponderadas por un peso w_{ij} entre 0 y 1. Este módulo interART tiene asociados dos parámetros (β_{ab} y ρ_{ab}) y un vector de salida x^{ab} .

En la Figura N°4.8 podemos ver una estructura de la red Fuzzy ARTMAP. El vector de entrada **a** a la red ARTa se transforma en su forma complementaria, **A**, mientras que para la red ARTb no es necesario calcular la forma complementaria del vector de entrada **b**. Los pesos de las conexiones del mapa, se inicializan todos a 1.

- **Entrenamiento**

Para entrenar la red Fuzzy ARTMAP, se presenta a la red ARTa el patrón de datos y a ARTb el vector de la salida deseada para ese patrón. La red utiliza una forma de clasificación mediante hipótesis. Cuando recibe el primer vector, deduce a que categoría pertenece. Con el segundo vector, Fuzzy ARTMAP puede confirmar o rechazar la hipótesis. Si la rechaza, el proceso se repite de nuevo.




Figura N°4.8: Esquema de la red neuronal Fuzzy ARTMAP.

Durante el proceso de entrenamiento, el aprendizaje de ARTa se desactiva ($\beta_a=0$) y se controla mediante Fuzzy ARTMAP. El parámetro de vigilancia de ARTa, ρ_a , varía durante el aprendizaje. Se denota el valor inicial de ρ_a como *baseline vigilance* $\bar{\rho}_a$ (factor de vigilancia referencia). El criterio de vigilancia de ARTb ρ_b se pone a 1 para diferenciar perfectamente los vectores de salida deseados.

Cuando los vectores **A** y **B** se presentan a ARTa y ARTb, ambas redes entran en resonancia, y se evalúa el criterio de vigilancia para

comprobar si el nodo ganador de ARTa se corresponde con el vector de salida deseado, presentado en ARTb:

$$\frac{|\mathbf{y}^b \wedge \mathbf{w}_J^{ab}|}{|\mathbf{y}^b|} \geq \rho_{ab} \dots\dots\dots(4.6)$$

Donde \mathbf{y}^b es el vector de salida de ARTb (el patrón de actividad de F_2^b), J es el índice del nodo ganador de F_2^a , \mathbf{w}_J^{ab} corresponde a los pesos de las conexiones del nodo J de F_2^a y $\rho_{ab} \in]0,1]$ es el parámetro de vigilancia del mapa interART. Si no se cumple el criterio, el factor de vigilancia de ARTa se incrementa lo justo para seleccionar otro nodo ganador ($\rho_a > |\mathbf{A} \wedge \mathbf{w}_J|/|\mathbf{A}|$, ver ecuación 4.4) y el vector \mathbf{A} se retropropaga en ARTa.

Cuando se cumpla el criterio de vigilancia, el mapa interART aprende la asociación entre los vectores A y B, modificando sus pesos según la ecuación 5.

$$\mathbf{w}_J^{ab} = \beta_{ab} \mathbf{x}^{ab} + (1 - \beta_{ab}) \mathbf{w}_J^{ab} \dots\dots\dots(4.7)$$

Los pesos de ARTa también se modifican, según la ecuación 4.5, y el factor de vigilancia se vuelve a poner a $\overline{\rho}_a$.

En términos de las hipercajas, el módulo interART de Fuzzy ARTMAP asocia un número de categoría a cada caja creada por ARTa. Este número es el índice del nodo emparejado de F_2^b . De este modo, cada categoría aprendida por la red Fuzzy ARTMAP se representa con varios rectángulos, es decir, aprende a distinguir los datos mediante cajas emparejadas en el espacio, asignando cada categoría a un número determinado de esas cajas.

▪ **Clasificación**

Una vez que el entrenamiento de Fuzzy ARTMAP se ha concluido, se puede utilizar como clasificador, dejando sin utilizar la red ARTb. Presentamos un patrón de entrada a ARTa, que se propaga hasta



entrar en resonancia, con un factor (temporal) de vigilancia $\rho_a = 0$. Así, se acepta la primera categoría que cumpla la función de selección. El aprendizaje de esta red también se desactiva temporalmente ($\beta_a = 0$).

El vector de salida del mapa interART se ajusta a:

$$\mathbf{x}^{ab} = \mathbf{w}_J^{ab} \dots\dots\dots(4.8)$$

Donde J es el índice del nodo ganador de F_2^a . Si el interART está utilizando un aprendizaje rápido ($\beta_{ab} = 1$), el vector de salida estará compuesto por un uno y el resto ceros. El índice de esa componente será la categoría en la que se ha clasificado el vector de entrada \mathbf{A} . La utilidad del módulo interART es simplemente la de asociar un número de categoría a cada nodo de la capa F_2 de ARTa (F_2^a), esto es, a cada caja del hiperespacio.

Si no se utiliza aprendizaje rápido, un nodo puede estar asociado a varias categorías en diferentes grados. Una forma de determinar el número de categoría podría ser seleccionar el índice de la componente mayor.



V.- MATERIALES Y MÉTODOS

Se siguió el esquema de principio establecido en la Metodología de la Investigación y como el presente trabajo es aplicado, se presenta la fundamentación teórica y las aplicaciones que se pueden hacer con nuestro diseño.

Para nuestro trabajo de investigación se utilizó una Laptop (ordenador portátil) y el programa Excel y el software de programación MATLAB y Visual C++.

El diseño de un modelo neuronal, dinámico y multi-escala para la segmentación de imágenes en color. Basado en aspectos biológicos presentes en el sistema visual humano, el modelo combina información cromática y textural para segmentar las imágenes de forma coherente. La arquitectura que se describe en el presente trabajo está constituida por dos módulos principales: el Sistema de Color Oponente (*Colour Opponent System*, COS) y el Sistema de Segmentación Cromática (*Chromatic Segmentation System*, CSS). En primer lugar, el módulo COS transforma la señal cromática de entrada RGB en las longitudes de onda de activación de los conos, fotorreceptores presentes en la retina de los mamíferos: longitud de onda larga (L), media (M) y corta (S), y en la señal de luminancia. Posteriormente, los dos tipos de células presentes en el módulo COS se encargan de componer procesos oponentes utilizando estas nuevas señales, generando el canal de luminancia y los canales L-M, S-(L+M). El módulo CSS incorpora los procesos de extracción de contornos y posterior difusión para lograr el resaltado coherente de las regiones de la imagen. La estructura del módulo CSS se basa en el modelo neuronal BCS/FCS, pero ampliado para permitir el procesamiento de los estímulos de color con el objetivo de conseguir una arquitectura de propósito general para la segmentación de imágenes con aplicaciones en visión artificial y reconocimiento de objetos. Esta arquitectura conserva las

cualidades esenciales del modelo tomado como base, como la extracción de contornos ilusorios, agrupamiento perceptual y eliminación de las variaciones de iluminación.

5.1- Modelo dinámico propuesto

La arquitectura del modelo propuesto (ver Figura N°5.1) se divide en dos componentes principales, denominados Sistema de Color Oponente (COS) y Sistema Cromático Segmentador (CSS).

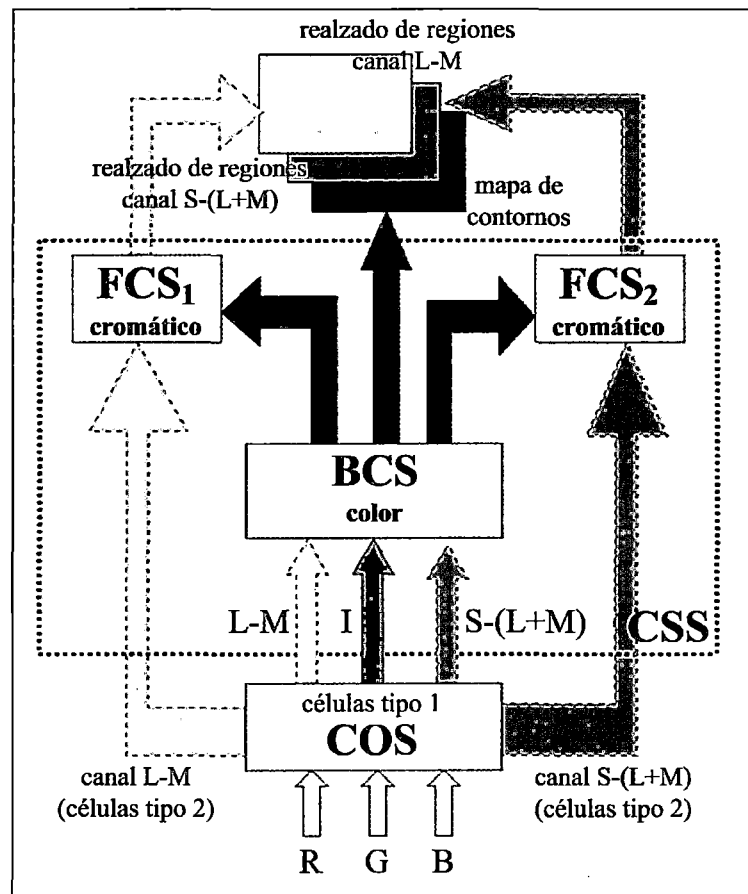


Figura N°5.1: Arquitectura del modelo propuesto. Las flechas punteadas de color claro (izquierda) representan las oponencias L-M, las flechas punteadas oscuras (derecha) constituyen las oponencias S-(L+M), las flechas lisas de color gris (centro) corresponden al canal de luminancia, y las flechas negras se corresponden con la información del mapa de contornos de la imagen.

El módulo COS se encarga de transformar las componentes cromáticas de la señal de entrada (RGB) a un nuevo sistema de codificación, de mayor valor fisiológico y computacional, constituido por varios canales cromáticos y una señal acromática o de luminancia. En primer lugar, el COS calcula las longitudes de onda de activación de los conos (longitudes de onda larga (L), media (M) y corta (S)), y a continuación genera las oponencias L-M y S-(L+M).

Las señales resultantes son transmitidas al módulo CSS, donde se genera la extracción de contornos y el resaltado de las regiones de la imagen mediante un procesamiento multi-escala. Las distintas etapas del sistema CSS se encargan de extraer los contornos de la imagen, realizar un refinamiento selectivo de los mismos atendiendo a mecanismos perceptuales, y rellenar de forma homogénea las regiones limitadas por dichos contornos con información cromática de cada una de las oponencias.

La salida del modelo propuesto consta de tres componentes: un mapa de contornos de la imagen, y dos segmentaciones correspondientes de los canales cromáticos oponentes antes mencionados, L-M y S-(L+M).

5.1.1- Sistema de Color Oponente (COS)

En el módulo Sistema de Color Oponente (COS, *Colour Opponent System*) se realizan procesos oponentes de color basados en los mecanismos oponentes presentes en la retina y en el Núcleo Lateral Geniculado (LGN) del sistema visual de los mamíferos [Hubel-95] [Wilson-90]. La Figura N°5.2 muestra la estructura detallada del módulo COS.

Esta etapa está compuesta por dos tipos de células, las de tipo 1 y la de tipo 2. Éstas inician los procesos necesarios para realizar la detección de contornos límite de color – “*colour boundary contours*” (células tipo 1, oponencia simple) y de contornos de características de color – “*colour feature contours*” (células tipo 2, doble oponencia) y que se completan en

el módulo CSS. Los contornos límite son sensibles a los contrastes claro-oscuro y generan el mapa de contornos que controla la difusión cromática determinada por los contornos de características de color.

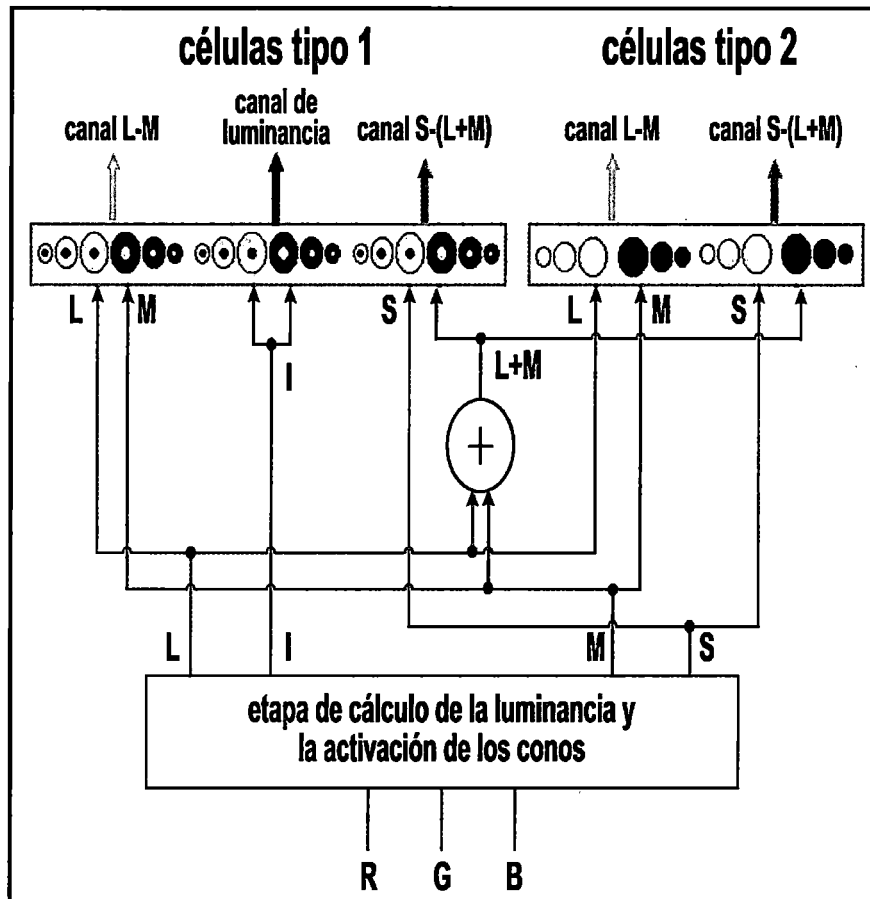


Figura N°5.2: Estructura detallada del modelo COS. A la izquierda se ven las células de tipo 1 y a la derecha las de tipo 2. Para ambos tipos se representan las células de tipo ON y OFF para cada una de las oponencias y el canal de luminancia (sólo tipo 1)

El módulo COS modela el funcionamiento de ambas células de forma paralela. Además, se realiza una etapa previa de pre procesamiento en la que la luminancia (I), las longitudes de onda de las activaciones de los conos (longitud de onda larga (L), media (M) y corta (S)) y la activación del canal (L+M), (Y), se genera a partir de las señales cromáticas de entrada (RGB). Las ecuaciones 5.1, 5.2 y 5.3 definen los cálculos de dichas actividades. La señal de luminancia (I) se calcula como una suma

ponderada [Gonzalez-02]; las señales L, M y S se obtienen a través de la matriz [Hubel-90] de transformación de las tres componentes cromáticas R, G y B.

$$I = 0.299R + 0.587G + 0.114B \dots\dots\dots (5.1)$$

$$\begin{bmatrix} L \\ M \\ S \end{bmatrix} = \begin{bmatrix} 0.293 & 0.603 & 0.104 \\ 0.134 & 0.704 & 0.162 \\ 0.046 & 0.099 & 0.854 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \dots\dots\dots (5.2)$$

$$Y = L + M \dots\dots\dots (5.3)$$

5.1.2- Sistema Cromático Segmentador

Como se ha comentado, el Sistema Cromático Segmentador (CSS, Chromatic Segmentation System) basa su estructura en el modelo modificado BCS/FCS [Grossberg-95] [Mingolla-99], adaptando su funcionamiento a las señales cromáticas oponentes para el procesamiento de imágenes en color. En la Figura N°5.3 se puede observar la estructura detallada del CSS.

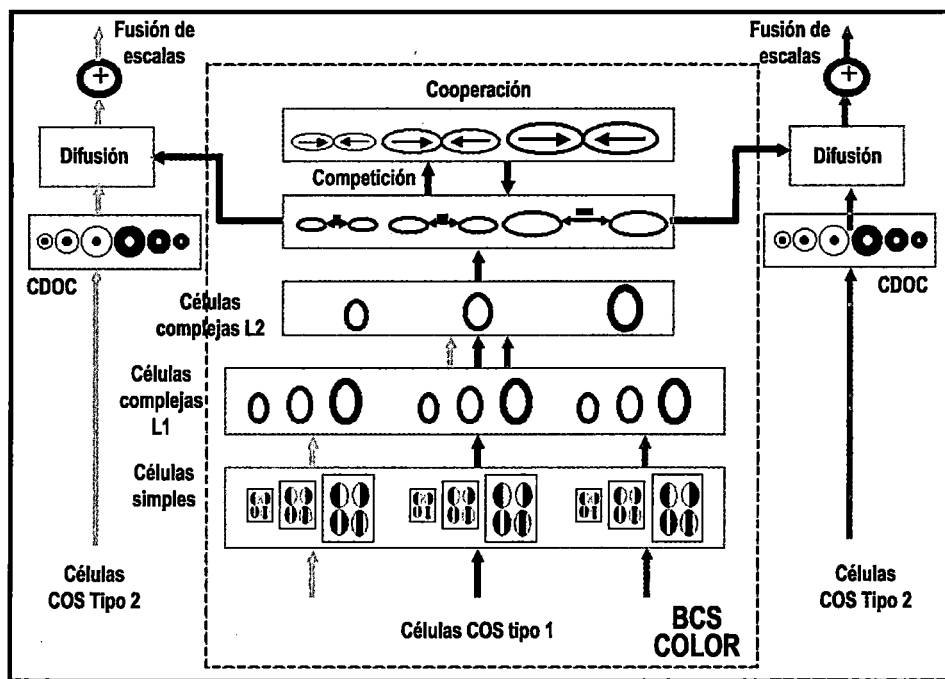


Figura N°5.3: Estructura detallada del Sistema Cromático Segmentador (CSS) basado en el modelo BCS/FCS.

A continuación se incluyen los cambios más significativos sobre el modelo original para procesar información de color:

- La etapa de realce del contraste (CES, *Contrast Enhancement Stage*) del modelo original se ha eliminado al haberse incluido previamente en las células oponentes de tipo 1 en el módulo COS.
- La etapa de células simples se aplica en paralelo sobre los canales oponentes propuestos (cromáticos y luminancia).
- Las funciones del modelo original que modelan la respuesta de las células simples a los contrastes (contornos) han sido sustituidas por Filtros de Gabor.
- Se ha dividido la etapa de células complejas en dos niveles: el primero de ellos se encarga de fusionar la información relativa a cada filtro de Gabor y el segundo combina las salidas de los tres canales oponentes para obtener un mapa de contornos unificado.
- En el módulo de difusión se ha añadido una etapa inicial, que simula el comportamiento de las células de doble oponencia cromática. Dicha etapa utiliza como entradas las salidas de las células oponentes de tipo 2 del módulo COS y constituye el paso previo a la difusión.
- El módulo de difusión se ha duplicado para obtener dos difusiones, una para cada oponencia cromática. El canal de luminancia se ha desechado en este punto al considerarse la base cromática L-M, S-Y suficiente para la caracterización de una imagen.
- Las dobles oponencias se generan en nuevas etapas CDOC.
- Las difusiones se realizan sobre dobles oponencias y no sobre simples como en el modelo original.

El módulo CSS consta de la etapa BCS Color y dos etapas de Difusión Cromática.

5.2- Implementación de la arquitectura

La ha implementado la arquitectura sobre una herramienta que permite la utilización del modelo sobre imágenes digitales. El objetivo de la herramienta ha sido el de generar un entorno de pruebas para el modelo, proveyendo a los usuarios una interfaz gráfica sencilla, intuitiva y modular donde modificar los numerosos parámetros del sistema y ver resultados intermedios.

5.2.1-Herramienta BCS FCS Color

La arquitectura ha sido implementada sobre una herramienta visual que permite la segmentación controlada de imágenes de entrada en color, mediante el manejo de los diferentes parámetros del modelo descrito. Debido a que la elección de los parámetros de la segmentación depende del tipo de imagen a tratar, máxime en un modelo multi-escala, proveer interfaces sencillas para el manejo de los mismos es un requisito indispensable.

5.2.2- Detalles de la implementación

La herramienta BCS FCS Color ha sido implementada sobre el entorno de programación Microsoft Visual C++ 6.0 y se puede utilizar en plataformas Windows. Se ha intentado dividir el código en dos partes diferenciadas: procesamiento matemático de las distintas etapas del modelo e interfaz gráfica de usuario. El objetivo ha sido facilitar su posterior migración a otros sistemas operativos y plataformas (al menos de todas las clases que contienen el procesamiento real del modelo).

Se ha empleado un paradigma de programación orientado a objetos de modo que cada una de las etapas del modelo viene representada por una clase C++. Así mismo, funciones utilizadas en varios módulos o funciones que presentan una cierta independencia (por ejemplo las Gaussianas o los filtros de Gabor) están modeladas mediante clases particulares.

El código es original de la realización del proyecto en casi su totalidad. Solamente se han empleado algunas librerías externas que se detallan a continuación:

- Librerías MFC de Microsoft Windows para la realización de la interfaz gráfica de usuario.
- Librería **ImageMagick** versión 6.2.2 (*ImageMagick and Magick ++ Libraries*) como soporte a la conversión entre formatos de imágenes y a la visualización de las mismas. En particular se han empleado las librerías Magick ++, aquellas programadas en C++. De la utilización de estas librerías surge el requisito de utilización de Service Pack 1 en el Visual C++. Sin esta actualización sería imposible tanto compilar las librerías como compilar código que las utilice.
- Se ha utilizado además un código de la Florida State University para generar el Ruido Gaussiano aditivo que se aplica a las imágenes de entrada.

5.2.2.1- La herramienta BCS FCS Color. Presentación y manual de usuario

▪ Menú principal y funcionamiento general

En la Figura N°5.4 se incluye una captura de pantalla de la aplicación. En ella se puede observar la modularidad la arquitectura en sus diferentes etapas. Cada bloque presente en la figura es el botón para entrar a los menús de cada etapa particular. La imagen inferior nos lleva al menú de selección de la imagen origen.

La herramienta desarrollada trabaja con proyectos, cada uno de ellos asociado a una imagen a segmentar. Cuando un usuario crea un nuevo proyecto se genera un fichero **.bfp** (BCS FCS Project) que guarda la configuración del proyecto (*path* del proyecto, parámetros, estado del proyecto) y un directorio con el mismo nombre del proyecto en el que se guardarán las salidas de los distintos módulos.

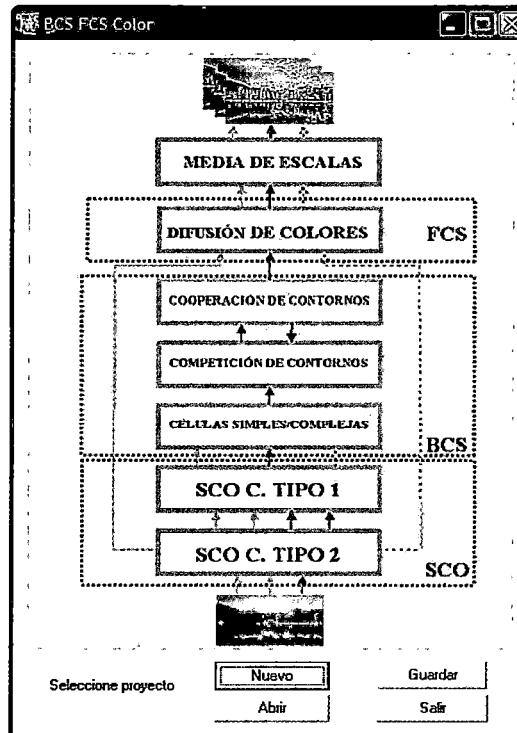


Figura N°5.4: Menú principal de la aplicación BCS FCS Color.

Se han creado una serie de parámetros por defecto que funcionan bien ante cualquier imagen; sin embargo, se recomienda modificar dichos parámetros si se desea mejorar el rendimiento en la segmentación. Durante el trabajo de un usuario con la aplicación todos los resultados son guardados en un directorio temporal (directorio Temp. En el árbol de la aplicación) de modo que únicamente al guardar el proyecto (botón Guardar) serán copiados al directorio del proyecto (sobrescribiendo todos los datos anteriores).

Los proyectos se componen pues de un fichero de configuración y las salidas de los módulos. Éstas son guardadas en ficheros de tipo **.double** que contienen matrices de números en formato double con los diferentes píxeles de la imagen. Las escalas y los distintos canales cromáticos generan salidas separadas pero, en caso de las salidas con contornos, las diferentes orientaciones se guardan en un mismo fichero. Con ello un fichero **.double** para una salida con un mapa de contornos contendría 12 matrices representando cada una de las posibles orientaciones.

M. J.

- **Selección de la imagen origen**

Una vez que el usuario ha creado el nuevo proyecto ha de elegir una imagen de origen presionando sobre la imagen en la parte de debajo de la pantalla principal. El menú de elección de origen permite al usuario incluir al proyecto imágenes de cualquier tamaño y de los formatos más habituales en las imágenes digitales (jpg, gif, png, tiff,...). En este mismo menú el usuario tiene la posibilidad de añadir ruido gaussiano aditivo a la imagen mediante un *slider* o rellenando la caja de texto asociada. La aplicación muestra el resultado de la incorporación de ruido a la imagen. La Figura N°5.5 contiene una representación de la pantalla de selección de origen. Como se puede observar este menú permite modificar la imagen en cualquier momento.




Figura N°5.5: Menú de selección de la imagen origen.

Una vez la imagen ha sido seleccionada, el usuario puede comenzar a ejecutar etapas de la arquitectura. Pinchando sobre las cajas de los módulos en Figura N°5.4, accederá al menú específico de cada una de las etapas.

▪ **Menú COS Células de tipo 2**

Este menú se corresponde con la ejecución de las células de tipo 2 del módulo COS. Se ha colocado previo a las células de tipo 1 debido a que se aprovecha también para obtener el canal de luminancia (que no pertenece directamente a este módulo).

Al ser el primero de los módulos descrito se comentarán aquí algunas de las características funcionales que son comunes a todas las etapas del sistema.

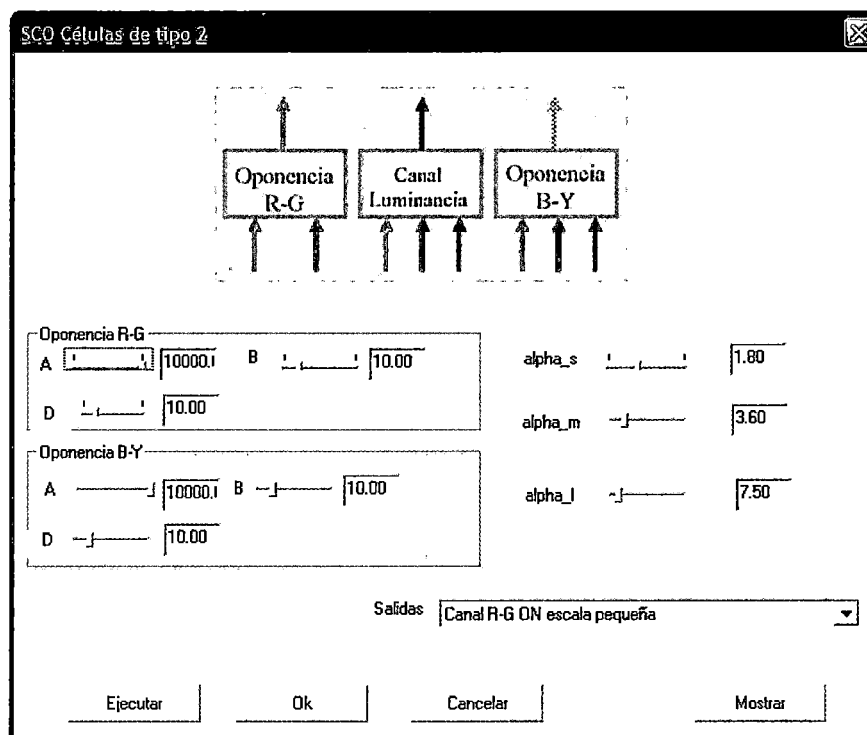


Figura N°5.6: Menú del módulo COS Células de tipo 2.

En la Figura N°5.6 se puede observar la presencia de cajas de texto o *sliders* (sincronizados) para modificar los parámetros del módulo (los cuales se cargan automáticamente según los parámetros iniciales o los guardados en el fichero de configuración del proyecto). Si el usuario aprieta el botón OK se saldrá del menú del módulo y los datos del mismo, valores de los parámetros y resultados en caso de que se haya ejecutado, serán guardados en memoria y en el directorio temporal respectivamente.

Si, por el contrario, el usuario sale del menú mediante el botón Cancelar se restaurará la configuración anterior. Esto se hace así ya que la aplicación genera ficheros temporales con los resultados anteriores a la entrada al módulo, que son restaurados si se utiliza esta opción.

Los parámetros de entrada en esta etapa se corresponden con aquellos mostrados en [De Valois-74a] y [De Valois-74b]:

- A: factor de decaimiento
- B: ponderador de Gaussianas
- D: Actividad de base

El módulo SCO Células de tipo 2 tiene 13 salidas:

- Oponencias L-M, con sus canales ON y OFF y sus tres escalas para cada canal (6)
- Oponencias S-Y, con sus canales ON y OFF y sus tres escalas para cada canal (6)
- Canal de Luminancia (1)

Si el módulo hubiese sido ejecutado, bien en la presente utilización de la aplicación o en alguna anterior que hubiese sido guardada, el usuario podrá ver los resultados desde la lista desplegable *Salidas*, seleccionando aquella salida (oponencia, escala) que desee ver. En la Figura N°5.7 se recoge una captura de pantalla del menú de visualización de salidas.

Este menú contiene la opción de guardar las salidas, muy útil para asegurar la utilidad de la herramienta. Precisamente este aspecto, junto con la modularidad de la herramienta, ha sido elegido para facilitar la elección de parámetros, la adaptación de la herramienta a las potenciales aplicaciones y para crear un entorno de aprendizaje y formación sobre el modelo.



Figura N°5.7: Menú de visualización de salidas.

▪ **Menú COS Células de tipo 1**

Las células de tipo 1 del módulo COS se ejecutan a continuación utilizando el canal de luminancia obtenido en la etapa anterior. La Figura N°5.8 muestra una captura de pantalla del menú de la interfaz de usuario.

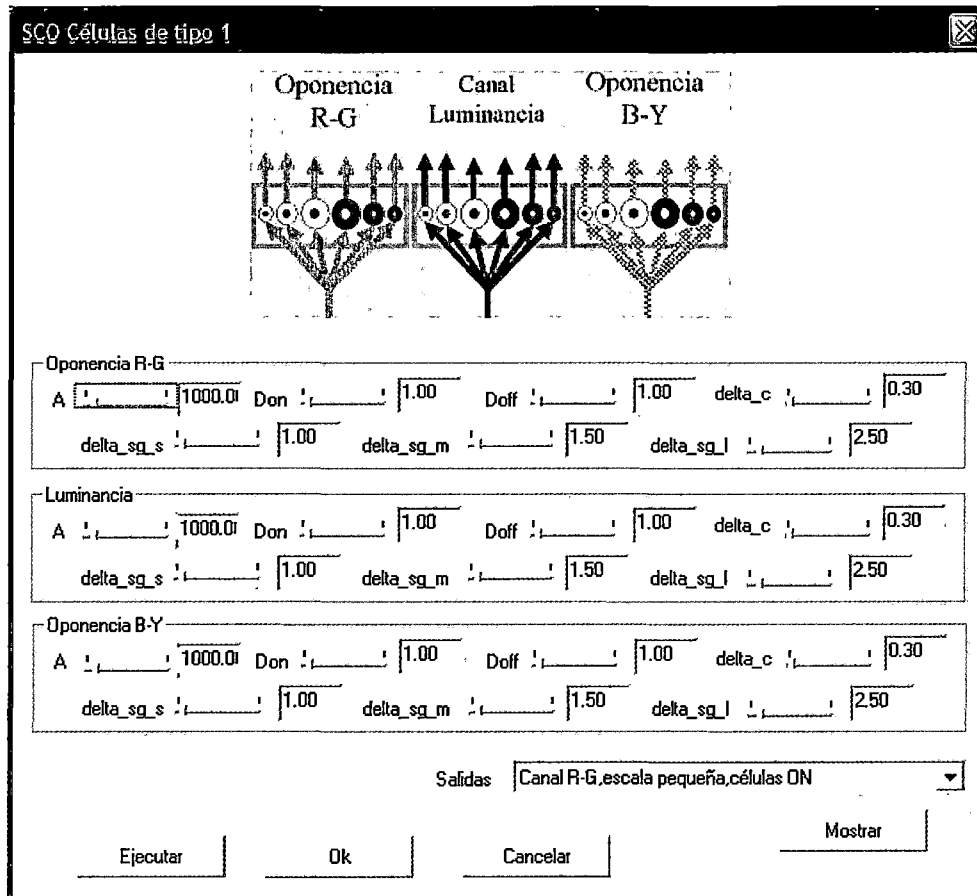


Figura N°5.8: Menú del módulo COS Células de tipo 1.

Los parámetros de entrada en esta etapa se corresponden con aquellos mostrados en [DeMonasterio-75a] y [DeMonasterio-75]:

- A: factor de decaimiento
- *Don* y *Doff*: Actividades de base
- *delta_c*: desviación típica de las Gaussianas de conectividad central
- *delta_sg_escala*: desviación típica de las Gaussianas de conectividad periférica en sus diferentes escalas

Es importante reseñar la no inclusión de parámetros que controlen las ponderaciones de las Gaussianas. En la implementación realizada dichos parámetros son controlados por la herramienta de forma que el área cubierta por las Gaussianas central y periférica es la misma. Aunque en

teoría no es necesario controlar este factor, el hecho de trabajar con datos discretos hace que el área de las Gaussianas varíe según su desviación típica (realmente se mide la Gaussiana en puntos discretos y eso no nos asegura un correcto funcionamiento, máxime cuando desviaciones típicas son muy pequeñas). En la etapa anterior esto no suponía un problema al utilizar una única Gaussiana.

El módulo SCO Células de tipo 1 tiene 18 salidas:

- Oponencias L-M, con sus canales ON y OFF y sus tres escalas para cada canal (6)
- Canal de Luminancia, con sus canales ON y OFF y sus tres escalas para cada canal (6)
- Oponencias S-Y, con sus canales ON y OFF y sus tres escalas para cada canal (6)

▪ **Módulo de Células Simples y Complejas**

En este módulo se ha integrado la funcionalidad de las células simples y las complejas, tomando como entrada las salidas de las Células de tipo 1 del SCO y obteniendo mapas de contornos reales de la imagen. Dicho módulo se puede ver en la Figura N°5.9.

Los parámetros de entrada en esta etapa se corresponden con aquellos mostrados en [Dreher-76] [Enroth Cugell-66] y [Enroth Cugell-73]:

- *F_escala*: frecuencia de las funciones trigonométricas de los filtros de Gabor para las diferentes escalas
- *delta_escala*: desviación típica de las Gaussianas de los filtros de Gabor para las diferentes escalas
- *A*, *B*, *C* y *D*: constantes ponderadoras de los diferentes filtros de Gabor



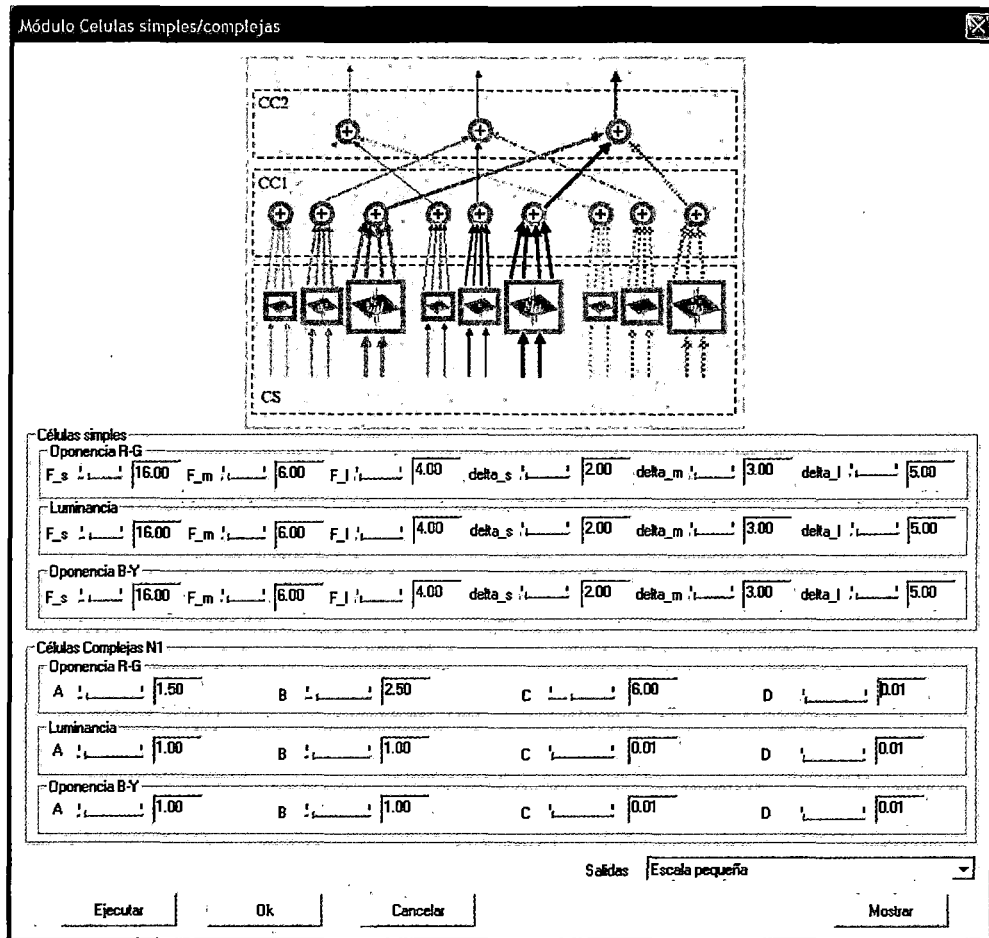


Figura N°5.9: Módulo de Células Simples/Complejas.

El módulo Células Simples / Complejas tiene 3 salidas:

- Escala pequeña: mapa de contornos reales para la escala pequeña
- Escala mediana: mapa de contornos reales para la escala mediana
- Escala grande: mapa de contornos reales para la escala grande

Como se ha comentado, las salidas de los mapas de contornos difieren del resto (contienen información dependiente de la orientación). Este hecho modifica también la visualización de las mismas (ver Figura N°5.10), de forma que ahora se ofrece un nuevo botón Rotar que permite navegar a través de los distintos mapas de contornos para cada una de

M. J.

las orientaciones (al final de la secuencia también se muestra la salida con la suma de las contribuciones de todos contornos).

En la figura se puede ver el aspecto de la interfaz gráfica del módulo.

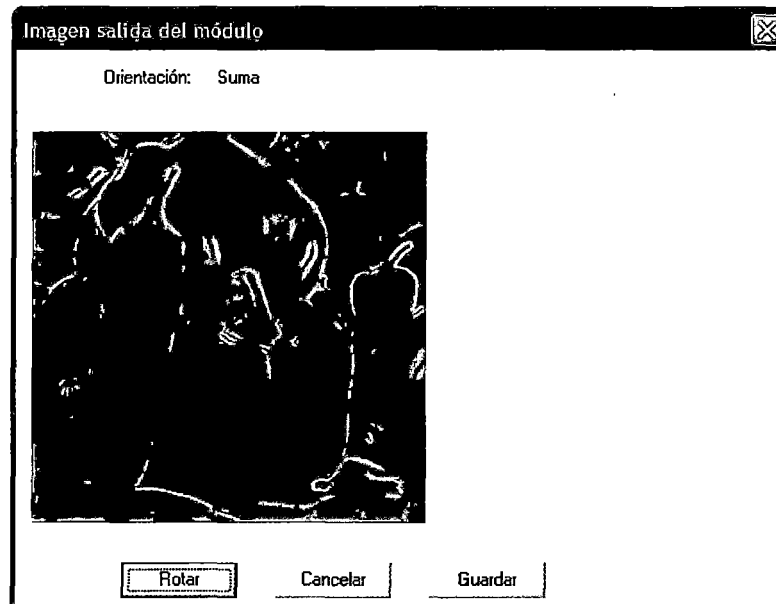


Figura N°5.10: Módulo visualizador de salidas de contornos.

▪ **Competición y cooperación de contornos**

Estas etapas también han sido agrupadas bajo un mismo módulo en la interfaz gráfica de usuario. La razón es que, en conjunto, forman el bucle que obtiene el mapa de contornos final de la imagen, reforzando los contornos importantes y eliminando aquellos poco significativos.

La interfaz gráfica del módulo se puede ver en la Figura N°5.11.

Los parámetros de entrada en esta etapa se corresponden con aquellos mostrados en [Gorras-68], [Grossberg-73], [Grossberg-84], [Grossberg-87b], [Grossberg-88] y [Grossberg-85a]:

- Competición:
 - o A: Factor de decaimiento
 - o B: Ponderador de las entradas
 - o C: Ponderador del término competitivo
 - o Gf. Ganancia hacia delante



- G_b : Ganancia hacia atrás
- delta_escala : desviación típica espacial para la función de competición mostrada en [Grossberg-73].
- delta_k : desviación típica orientacional para la función de competición mostrada en [Grossberg-73].

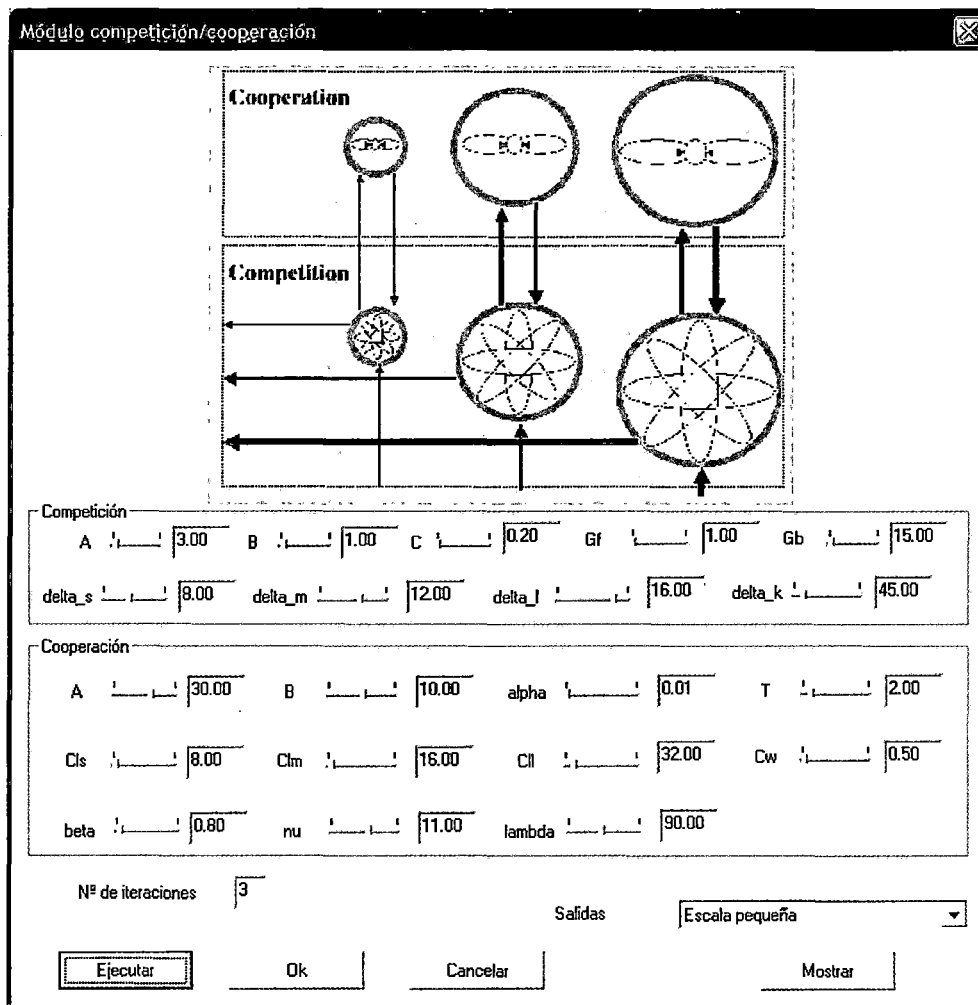


Figura N°5.11: Módulo de Competición/Cooperación de contornos.

- Cooperación:
 - A : Factor de decaimiento
 - B : Ponderador del término cooperativo
 - α : factor de decaimiento de la puerta estadística
 - T : umbral de la puerta estadística

M

- *Cl_escala*: variables de control sobre la longitud del dipolo para las diferentes escalas
- *Cw*: variables de control sobre el ancho del dipolo
- *beta*: parámetro que controla la distancia al centro del dipolo
- *nu*: parámetro que controla la desviación espacial respecto a la colinearidad
- *lambda*: parámetro que controla la desviación orientacional respecto a la colinearidad

El módulo Competición/Cooperación de contornos tiene 3 salidas:

- Escala pequeña: mapa de contornos finales para la escala pequeña
- Escala mediana: mapa de contornos finales para la escala mediana
- Escala grande: mapa de contornos finales para la escala grande

▪ **Difusión de colores**

El módulo Difusión de Colores de la interfaz gráfica contiene las etapas CDOC y difusión del modelo propuesto. Es decir, en este módulo se realiza el procesamiento cromático final para luego difundir los resultados en las regiones rodeadas por los contornos finales de la imagen. La Figura N°5.12 contiene una representación del mismo.

Los parámetros de entrada en esta etapa se corresponden con aquellos mostrados en [DeMonasterio-75a] y [DeMonasterio-75b], al poseer las mismas ecuaciones que el módulo SCO Células de tipo 1, [Grossberg-85b] y [Grossberg-87b] en lo referente a la difusión.

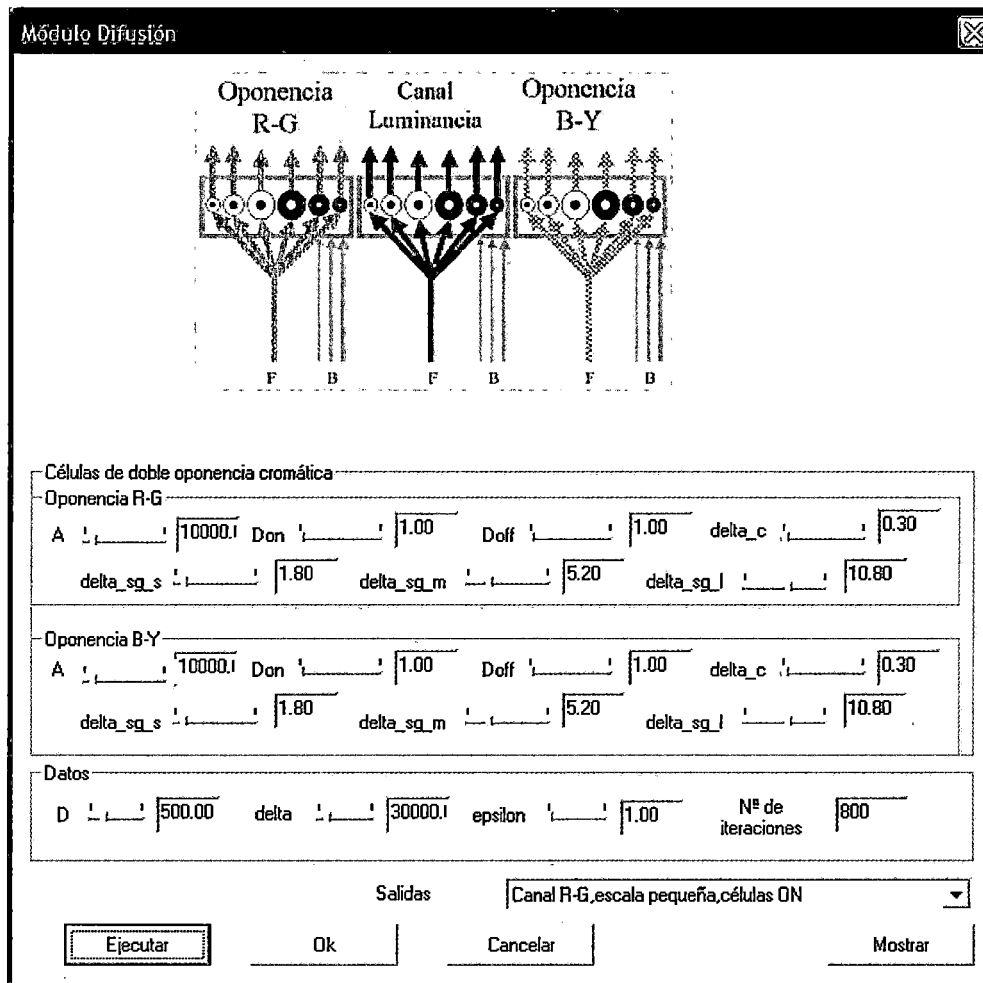


Figura N°5.12: Módulo Difusión.

En este punto solamente se tomaran en cuenta los parámetros de la difusión, para las células CDOC se pueden ver en Figura N°5.9:

- D: factor de decaimiento
- delta: parámetro controlador de la permeabilidad de la difusión
- epsilon: parámetro controlador de las barreras de la difusión
- N° de iteraciones: al ser la difusión un proceso iterativo.

El módulo Difusión tiene 12 salidas:

- Oponencias L-M, con sus canales ON y OFF y sus tres escalas para cada canal (6)
- Oponencias S-Y, con sus canales ON y OFF y sus tres escalas para cada canal (6)

▪ Módulo Fusión de escalas

El último módulo de la arquitectura realiza la fusión entre las distintas escalas de trabajo. Como se puede en la Figura N°5.13, aparte de los típicos parámetros que controlan el funcionamiento de la etapa, en este módulo se ofrece la posibilidad de ejecutar un procesamiento *batch* (Botón Ejecución Batch). Como se explica en la figura, la herramienta obtiene los valores de los parámetros de cada uno de los módulos y realiza la ejecución de todas las etapas en serie. Es interesante ofrecer esta posibilidad para realizar pruebas no supervisadas una vez que se conocen los parámetros adecuados.

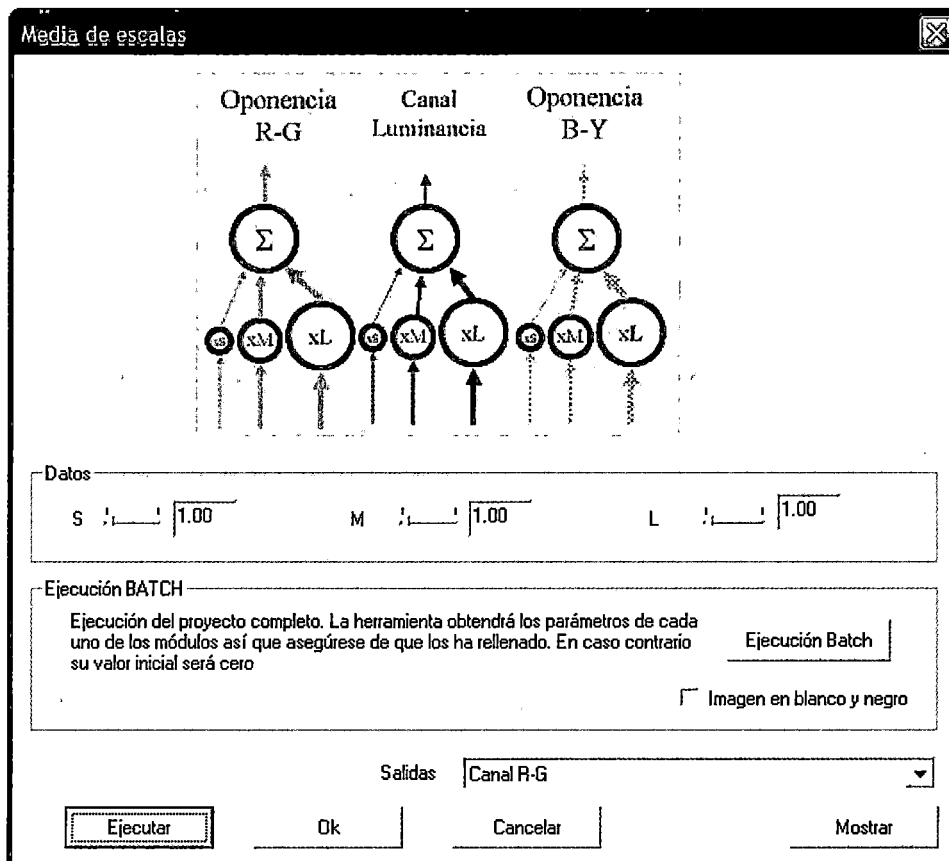


Figura N°5.13: Módulo Fusión de escalas.

Los parámetros de entrada en esta etapa se corresponden con aquellos mostrados en [Grossberg-88]:

- S: Ponderador de la escala pequeña
- M: Ponderador de la escala mediana
- L: Ponderador de la escala grande

El módulo Fusión de escalas tiene 6 salidas:

- Canal L-M: salida final de la segmentación para el canal L-M
- Canal L-M con contornos: salida final de la segmentación para el canal L-M superpuesto con el mapa de contornos. Esta salida es interesante para ver cómo los contornos constituyen las barreras a la difusión.
- Canal S-Y: salida final de la segmentación para el canal S-(L+M)
- Canal S-Y con contornos: salida final de la segmentación para el canal S-(L+M) superpuesta con el mapa de contornos



VI.- RESULTADOS

En esta sección se incluyen los resultados obtenidos por el modelo ante diferentes imágenes de entrada y distintos niveles de ruido.

Para la realización de las pruebas se han elegido las imágenes en color mostradas en la Figura N°6.1.




Figura N° 6.1: Imágenes de color utilizadas en las pruebas. Arriba-izquierda: Mandril. Arriba-centro: Aérea. Arriba-izquierda: Texturas. Abajo-izquierda: Pirámide. Abajo-derecha: Roca. Pertenecen a Berkeley Segmentation Dataset and Benchmark [Berkeley].

En estas imágenes se aprecian regiones definidas según sus características de color y textura. Se trata, por lo tanto, de imágenes muy significativas para los objetivos de nuestra arquitectura. Los tamaños elegidos son de 256x256 y 383x256 píxeles, con formato RGB, 8 bits por píxel y color (tres canales con valor binario comprendido entre 0 y 255).

Se han tomado imágenes con características muy diversas para validar la arquitectura de una forma general frente a requisitos cambiantes (de escala, cromáticos, de texturas...). Las imágenes e) y f) pertenecen al Berkeley Segmentation Dataset and Benchmark de la Universidad de California, disponible en [Berkeley].

Los parámetros del modelo utilizados para las simulaciones realizadas se presentan en la Tabla N° 1:

Tabla N° 1: Valores de los parámetros de la arquitectura propuesta para las pruebas realizadas.

Células COS Tipo 1				
Oponencias L-M, S-(L+M) y Luminancia				
A	1000.0	σ_c		0.3
C	1.0	σ_{ss}		0.5
B	1.0	σ_{sm}		1.0
D ⁺	1.0	σ_{sl}		1.8
D ⁻	1.0			
Células COS Tipo 2				
Oponencias L-M y S-(L+M)				
A	10000.0	σ_s		0.3
B	10.0	σ_m		0.8
D ⁺	10.0	σ_l		1.6
D ⁻	10.0			
Células Simples				
Oponencias L-M, S-(L+M) y Luminancia				
F _s	12.0	σ_{ss}		8.0
F _m	8.0	σ_{sm}		12.0
F _l	5.0	σ_{sl}		15.0
Células Complejas				
Oponencias L-M, S-(L+M) y Luminancia				
γ	1.0	ξ		0.01
κ	1.0	υ		0.01
Células de Competición				
A	3.0	G _f	1.0	σ_m 8.0
B	1.0	G _b	15.0	σ_l 16.0
C	0.2	σ_s	4.0	σ_k 45.0
Células de Cooperación				
A	3.0	C _{lm}	1.0	T 2.0
B	1.0	C _{ll}	15.0	μ 11.0
C _{ls}	0.2	C _{ws} , C _{wm} , C _{wl}	4.0	β 0.8
Células CDOC				
Oponencias L-M y S-(L+M)				
A	10000.0	σ_{ss}		1.2
D ⁺	1.0	σ_{sm}		5.2
D ⁻	1.0	σ_{sl}		10.8
σ_c	0.3	σ_{ss}		1.2
Etapa de Difusión		Fusión de Escalas		
D	150.0	A ₀		8.0
δ	20000.0	A ₁		2.0
ε	30.0	A ₂		1.0

La Figura N° 6.2 muestra una comparativa entre las salidas de las células oponentes tipo 1 y tipo 2 del módulo COS para el canal oponente L-M de la imagen del Mandril. Como ya se ha mencionado, las células COS de tipo 1 poseen la capacidad para realzar los contrastes, de tal modo que, en sus salidas, los límites entre regiones aparecen reforzados gracias a las diferentes características cromáticas y lumínicas con respecto a sus alrededores. Por otro lado, las células COS tipo 2 participan en la difusión cromática, alisando las variaciones de los valores cromáticos con respecto a sus alrededores. Es necesario destacar también el procesamiento multi-escala. Mientras que las escalas pequeñas aportan una gran precisión en los contrastes, las escalas más grandes tiende a suavizar las regiones (como se puede ver en el brillo de la nariz del Mandril) y son más sensibles a los contrastes amplios.




Figura N° 6.2: Comparación entre las células COS tipo 1 (fila superior) y las tipo 2 (fila inferior) para el canal L-M ON y las tres escalas espaciales.

El canal de luminancia juega un papel crucial en la extracción de características de primer orden para el resaltado de los contornos y la

detección de texturas (células COS de tipo 1), como se puede observar en la Figura N°6.3. El canal de luminancia es más sensible a los contrastes ya que la señal se opone contra sí misma (ver Tabla N°1), lo que aumenta la intensidad de las regiones ante la presencia de otras con distintas características (regiones fronterizas). Sin embargo, el procesamiento de la luminancia simplemente no es suficiente para obtener resultados adecuados en las imágenes de color y debe completarse con la información de los canales cromáticos (hay que recordar que los contrastes en las imágenes de color pueden desaparecer o ser difuminados en exceso al convertir las imágenes de color a escala de grises). Un ejemplo claro se puede encontrar en la percepción de la boca del Mandril. Se observan mejores resultados en la oponencia L-M (Figura N°6.3) que en el canal de luminancia (Figura N°6.4).




Figura N°6.4: Salidas del canal de luminancia (ON-OFF) de las células COS de tipo 1 para las tres escalas espaciales.

En la Figura N°6.4, se muestran los mapas finales de contornos obtenidos del módulo BCS Color (de la salida de las células de competición). Esta etapa es interesante destacar la diferencia entre las escalas. La escala pequeña obtiene mayor precisión y sensibilidad a los contrastes, aunque presenta altos niveles de ruido (por ejemplo, en el pelo del Mandril), mientras que la escala grande consigue menor precisión y sensibilidad ante contrastes, pero mayor filtrado de ruido. Esta importante característica del modelo propuesto se puede observar claramente en los resultados presentados. El módulo BCS Color extrae el contorno de la nariz del Mandril de forma continua. Esto se consigue gracias a la

M. J.

interacción entre los procesos de competición y de cooperación, que generan mecanismos de interpolación de contornos y de extracción de contornos ilusorios.




Figura N°6.4: Mapa de contornos final para las tres escalas. Salidas de la etapa de competición.

A continuación mostramos las salidas de las Células de Doble Oponencia Cromática, CDOC (ver Figura N°6.5). Estas células, como etapa previa a la difusión, diferencian y suavizan las regiones con características cromáticas independientes y, además, reaccionan fuertemente ante contrastes cromáticos.




Figura N°6.5: Salidas de las Células de Doble Oponencia Cromática (CDOC) para las tres escalas espaciales. Fila superior: CDOC L-M ON. Fila inferior: CDOC L-M OFF.

Es sencillo asociar los resultados de las diferentes escalas según los requisitos de la aplicación final. La escala pequeña mantiene un elevado grado de precisión para el procesamiento de los objetos más pequeños, como los ojos (distinguiendo iris y pupila), mientras que la escala grande genera una segmentación más pura con regiones uniformes y perfectamente diferenciadas.




Figura N°6.6: Salidas finales del modelo. Izquierda: Canal L-M. Centro: Canal S-(L+M). Derecha: Salida en color. La salida en color se genera como una imagen RGB donde la componente R almacena la salida del canal L-M, la componente G almacena la salida del canal S-Y, y la B permanece vacía (imagen negra).

Handwritten signature

En la Figura N°6.6 se muestran las salidas finales de nuestro modelo (L-M y S-Y), tras fusionar la información de las tres escalas en la etapa de Fusión (ver los parámetros utilizados en la Tabla N° 1). Como puede observarse, la información cromática y textural aparece ahora homogeneizada en el interior de cada una de las regiones de la imagen. La tercera imagen muestra una salida en color (codificación RGB) para una mejor visualización, donde la componente roja (R) se rellena con la salida del canal L-M, la componente verde (G) con la salida del canal S-(L+M), y la componente azul (B) se mantiene vacía.

Hay diversos aspectos destacables en las respuestas finales del modelo. En la imagen del Mandril se han resaltado siete regiones homogéneas: la nariz, los ojos, la boca, la frente, los pómulos, el pelaje y la zona que cubre el pelaje amarillento (esquina inferior izquierda) y la barba del mandril. En la imagen Aérea se distinguen diferentes zonas de la ciudad, el centro urbano (en rojo en la salida final), los barrios de alrededor (en tonos anaranjados), la zona despoblada (verdes), el río y el puerto. Una segmentación de este tipo podría utilizarse en estimaciones de población sobre áreas urbanas. Con la imagen de la Roca se han obtenidos resultados muy satisfactorios, tanto en la roca como en el árbol, ambas regiones con una elevada información textural que el modelo ha identificado y uniformado. Es interesante resaltar cómo el modelo ha homogeneizado el cielo; la imagen original muestra un cierto gradiente de color (es azul oscuro en la esquina superior izquierda y azul claro en la derecha) que, de forma adecuada, no se detecta en la extracción de contornos del sistema, y posteriormente se uniformiza en la etapa de difusión.

VII DISCUSIÓN

Para evaluar la capacidad de nuestro modelo para extraer contornos, lo comparamos con el ampliamente conocido extractor de Canny. Para ello utilizamos la función `cvCanny()` de la biblioteca de Visión Artificial de Intel, OpenCv [Intel-06]. Se han elegido los parámetros adecuados para conseguir los mejores resultados. Para la imagen del Mandril, utilizamos: `umbral1=2000`, `umbral2=1000`, y tamaño de apertura=5; para la imagen Aérea: `umbral1=200`, `umbral2=200`, y tamaño de apertura=3; y para la imagen de la Pirámide: `umbral1=10000`, `umbral2=5000`, y tamaño de apertura=7.




Figura N°7.1: Comparación con el extractor de Canny para las siguientes imágenes: Mandril (arriba), Aérea (medio), Pirámide (abajo).

En la Figura N°7.1, la columna izquierda muestra la estructura de contornos de generada por nuestro sistema, mientras que la columna derecha muestra los resultados del extractor de Canny. Como ya se han comentado anteriormente, se puede observar que la estructura de contornos de la imagen del Mandril obtenida por nuestro sistema incluye la parte inferior de la nariz como un contorno continuo, al contrario de lo que sucede con la obtenida con Canny, que no consigue extraer el contorno de la nariz como una línea continua. Esto es debido a que nuestro modelo utiliza un bucle competitivo-cooperativo para la extracción de contornos ilusorios, que es capaz de detectar los contornos perceptuales. En la imagen Aérea se puede ver cómo responde nuestro modelo frente a imágenes con muchos detalles, con contornos muy finos, demostrando un gran nivel de precisión en la escala pequeña. Por último, la imagen de la Pirámide nos permite observar el comportamiento del modelo en el procesamiento de imágenes con la escala grande. Se obtienen contornos muy definidos y una fuerte eliminación del ruido, lo que no sucede en la extracción de Canny.

Como se ha comentado con anterioridad las imágenes de la Pirámide y la Roca pertenecen al *Berkeley Segmentation Dataset and Benchmark* [Berkeley], utilizado previamente para entrenar y probar sistemas extractores de contornos frente a resultados sobre usuarios reales (los contornos que ellos detectan en su sistema preatentivo). La Figura N°7.2 muestra una comparativa entre segmentaciones de usuarios reales realizadas por Berkeley y los resultados de aplicar los módulos de extracción de contornos (células simples, complejas y bucle de competición-cooperación) a las imágenes resultantes de nuestra segmentación. Como se puede observar, los resultados obtenidos se aproximan bastante a la percepción obtenida por humanos en las imágenes presentadas, lo cual aporta gran validez a las segmentaciones obtenidas.




Figura N°7.2: Comparación entre las segmentaciones obtenidas por usuarios reales (dos primeras columnas) en las pruebas de Berkeley y la arquitectura propuesta (tercera columna).

Para mostrar cómo los resultados obtenidos por nuestra arquitectura favorecen el proceso de segmentación en comparación con otros modelos de segmentación, utilizamos la imagen Aérea. La Figura N°7.3a muestra la imagen del etiquetado de la imagen RGB original etiquetada utilizando la misma red de categorización Fuzzy ART, con el mismo parámetros de vigilancia ($\rho=0.9$).

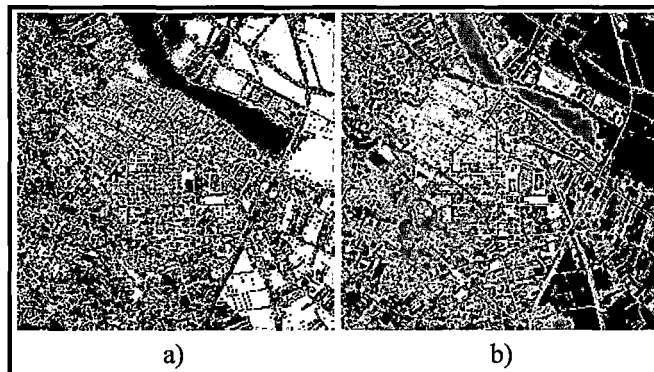


Figura N°7.3: Comparación con otros métodos de segmentación. **a)** Imagen original RGB etiquetada. **b)** Resultado de la segmentación piramidal.

Esta forma de categorización crea 10 categorías. Además, segmentamos la misma imagen Aérea mediante un modelo piramidal (ver La Figura N°7.3b). Utilizando la función `cvPyrSegmentation()` de la biblioteca de Visión Artificial de OpenCv [Intel-06]. Los parámetros necesarios se eligen

para obtener el mejor resultado visual posible (umbral1=70 y umbral2=30). Para ver el resultado, asignamos un nivel de gris diferente a cada región obtenida en la segmentación.



VIII REFERENCIALES

- [Beck-83] BECK J. **Textural Segmentation, Second-Order Statistics, and Textural Elements.** Biological Cybernetics, Vol 48: 125-130. Septiembre 1983.
- [Canny-86] CANNY, J. **A Computational Approach To Edge Detection,** IEEE Trans. Pattern Analysis and Machine Intelligence, Vol 8: 679-714. Noviembre 1986
- [Carpenter-89] CARPENTER G.A: **Neural network models for pattern recognition and associative memory.** Neural Networks, Vol 2: 243-257. Junio 1989
- [Carpenter-03] CARPENTER, G.A. **The default ARTMAP algorithm and its parameter values specified here define a ready-to-use general-purpose neural network system for supervised learning and recognition,** Neural Networks, Proceedings of the International Joint Conference. Vol 2: 1396-1401. Julio 2003.
- [De Valois-74b] DE VALOIS RL, MORGAN HC & SNODDERLY DM. **Psychophysical studies of monkey vision. III. Spatial luminance contrast sensitivity tests of macaque and human observers.** Vision Res, Vol 14: 53-67. Enero 1974
- [De Valois-74a] DE VALOIS RL, MORGAN HC, POOLSON MC, MEAD WR & HULL EM. **Psychophysical studies of monkey vision. I Macaque luminosity and colour vision tests.** Vision Res, Vol 14: 53-67. Enero 1974.
- [DeMonasterio-75a] DE MONASTERIO FM & GOURAS P. **Functional properties of ganglion cells of the rhesus monkey retina.** The Journal of Physiology, Vol 251: 167-195. Setiembre 1975.

- [DeMonasterio-5b] DE MONASTERIO FM, GOURAS P & TOLHURST DJ. **Concealed colour opponency in ganglion cells of the rhesus monkey retina.** J.Physiol, Vol 251: 197-216 Setiembre 1975.
- [Dreher-76] DREHER B, FUKADA Y & RODIECK, RW **Identification, classification, and anatomical segregation of cells with X-like and Y-like properties in the lateral geniculate nucleus of macaques.** J.Physiol. Vol 258: 433-452. Junio 1976.
- [Duda-73] DUDA, R.O. & HART, P.E. **Pattern Classification and Scene Analysis**, Editorial John Wiley, New York. Primera edicion 1973
- [Dunn-73] Dunn J. C. **A Fuzzy Relative of the ISODATA Process and Its Use in Detecting Compact Well-Separated Clusters,** Journal of Cybernetics Vol 3: 32-57. Setiembre 1973.
- [Enroth Cugell-66] ENROTH-CUGELL C & ROBSON JG **The Contrast Sensitivity of Retinal Ganglion cells of the cat.** J.Physiol, Vol 187: 517-552. Diciembre 1966
- [Enroth Cugell-73] ENROTH-CUGELL C & SHAPLEY RM **Adaptation and dynamics of the retinal ganglion cells of the cat.** J.Physiol , Vol 233: 271-309. Setiembre 1973
- [Fukushima-80] FUKUSHIMA K. **Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position.** Biological Cybernetics, Vol 36: 193-202. Abril 1980
- [Gouras-68] GOURAS P. **Identification of cone mechanisms in monkey ganglion cells.** J.Physiol, Vol 199: 533-547. Diciembre (1968)

- [Grossberg-85a] GROSSBERG S. & MINGOLLA, E. **neural dynamics of perception grouping: texture, boundaries, and emergent segmentations.** Perception and Psychophysics, Vol 38, 141-171. Agosto 1985.
- [Grossberg-85b] GROSSBERG S. & MINGOLLA, E. **Boundary completion, illusory figures, and neon color spreading.** Psychological Review, Vol 92: 173-211. Abril 1985
- [Grossberg-87b] GROSSBERG S. & MINGOLLA, E. **Neural dynamics of surface perception: Boundary webs, illuminants, and shape-from-shading.** Computer Vision, graphics, and Image processing, Vol 37: 116-165. Enero 1987
- [Grossberg-73] GROSSBERG S. **Contour enhancement, short term memory, and constancies in reverberating neural networks.** Studies in Applied Mathematics, Vol 52: 217-257. Enero 1973.
- [Grossberg-84] GROSSBERG S. **Outline of a theory of brightness, colour, and form perception.** Advances in Psychology, Vol 20: Abril 1984
- [Grossberg-87a] GROSSBERG, S. **Cortical dynamics of three-dimensional form, color and brightness perception. I. Monocular theory.** Perception and Psychophysics, Vol 41: 87-116. Marzo 1987
- [Grossberg-88] GROSSBERG, S., & TODOROVICH, D. **Neural dynamics of 1-D and 2-D brightness perception: A unified model of classical and recent phenomena.** Perception & Psychophysics, Vol 43: 241-277. 1988.
- [Grossberg-95] GROSSBERG, S., MINGOLLA, E. & WILLIAMSON, J. **Synthetic aperture radar processing by a multiple scale neural system for boundary and surface representation.** Neural Networks, Vol 8:

1005-1028. Marzo 1995.

- [Hecht Nielsen-87] HECHT-NIELSEN R. **Counter propagation networks.** Applied Optics, Vol 26: 4979-4984. Diciembre 1987.
- [Horowitz-76] HOROWITZ, K.J. & PAVLIDIS, T. **Picture segmentation by a tree traversal algorithm.** Journal of the Association for Computer Machinery Vol 23(2):368-388. Abril 1976
- [Julesz-81] JULESZ B. **A theory of Preattentive Texture Discrimination Based on First-Order Statistics of Textons.** Biological Cybernetics, Vol 41: 131-138. Agosto 1981.
- [Julesz-87] JULESZ B., & BERGEN R. **Textons, The Fundamental Elements in Preattentive Vision and Perception of Textures.** In Fischer and Firschen (eds.). Readings in Computer Vision, Vol 243-256, Julio 1987.
- [Kohonen-84] KOHONEN T. **Self-organization and associative memory.** Alemania Editorial Springer-Verlag, Primera edición 1984.
- [MacQueen-67] MACQUEEN. J. **Some methods for classification and analysis of multi-variate observations.** Proceedings of the Fifth Berkeley Symp. on Math., Statistics and Probability. Vol 1: 281-297. Enero 1967.
- [McCulloch-43] MCCULLOCH W.S. & PITTS W. **A logical calculus of the ideas immanent in nervous activity.** Bulletin of Mathematical Biophysics, Vol 59, 127-147. Diciembre 1943.
- [Nobuyuki-79] NOBUYUKI OTSU, **A threshold selection method from gray-level histogram,** IEEE Transactions on System Man Cybernetics, Vol. SMC-9, No. 1: 62-66. Enero 1979
- [Pratt-01] PRATT W. K. **Digital Image Processing,** Editorial John Wiley & Sons Inc. Tercera edición. 2001.

- [Prewitt-70]** **PREWITT J. in Picture Processing and Psychopictories**, Lipkin B. and Rosenfeld A., Editores New York, Primera edicion USA. 1970.
- [Roberts-65]** **ROBERTS L. G. in Optical and Electro-Optical Information Processing**, Massachusetts of Technology Press Institute, Editores T Berkowitz D.A and Tippett J.T. pp 159-197. Año 1965.
- [Sobel-78]** **SOBEL I. neighbourhood coding of binary image for fast contour following and general binary array processing**, Computer Graphics and Image Processing, Vol 8, 127-135. Agosto 1978.
- [Yakimovsky-76]** **YAKIMOVSKY, Y. Boundary and object detection in real world images**, Journal of the Association for Computer Machinery Vol 23 (4): 599-618. Octubre 1976.



IX APÉNDICE

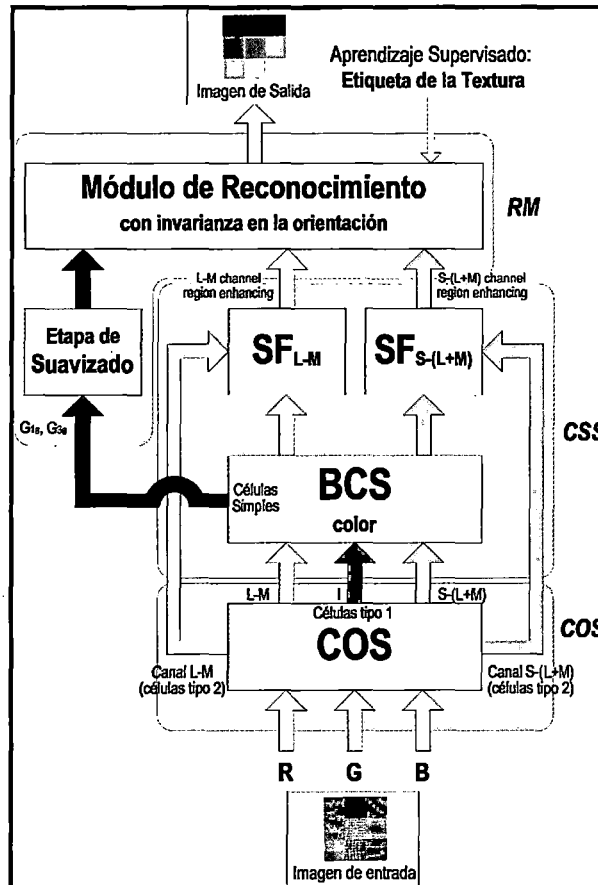


Figura N° 9.1: **[Autoría propia]** Arquitectura del modelo propuesto integrando el módulo de reconocimiento y el Sistema de Color Oponente (COS), el Sistema Cromático Segmentador (CSS), que forman parte de la fase de segmentación, y el Módulo de Reconocimiento (RM).

El modelo diseñado realiza las regiones de la imagen como pre-procesamiento anterior a la segmentación. Por lo tanto, el proceso inmediatamente posterior, para obtener la segmentación, es el etiquetado de las regiones. Éste se realiza haciendo que a todos los puntos de la misma región se les asocie la misma etiqueta. Por lo tanto, el realzado de las regiones de la imagen facilita mucho el proceso de etiquetado y lo hace más eficiente. Con el objetivo de probar lo anteriormente expuesto, utilizamos una red de categorización Fuzzy ART [Carpenter-91], de forma

que a todos los puntos que pertenecen a la misma región se les asigne el mismo nombre de etiqueta. Para cada punto de la imagen, tenemos un patrón de dos componentes, la dos salidas de la etapa de fusión de escalas (canales L-M y S-(L+M)). De esta forma, la imagen con la segmentación se genera etiquetando todos los puntos de acuerdo a su categoría de patrón, asignando un nivel de gris diferente para cada categoría.

La Figura N°9.2 se muestra la categorización para las imágenes Aérea y Mandril. En ambos casos el valor utilizado como parámetro de vigilancia es $\rho=0.9$. Las categorías obtenidas son 7 y 9, respectivamente.




Figura N°9.2:[Autoría propia] Salida del modelo etiquetado mediante la red neuronal Fuzzy ART. Parámetro de vigilancia $\rho=0.9$. a) Mandril, se crean 9 categorías. b) Aérea, se crean 7 categorías.

Para mostrar cómo los resultados obtenidos por nuestra arquitectura favorecen el proceso de segmentación en comparación con otros modelos de segmentación, utilizamos la imagen Aérea.

19

X. ANEXOS

- **Matriz de Consistencia**

Título: “DISEÑO DE UN MODELO NEURONAL PARA EL RECONOCIMIENTO DE IMÁGENES Y COLOR”

PROBLEMAS	OBJETIVOS	HIPOTESIS	VARIABLES	MATERIALES Y MÉTODOS
<p>General</p> <p>La buena calidad de los sistemas de reconocimiento de imágenes y Color, es importante para garantizar la fidelidad de la imagen reconstruida o procesada, que su vez se aplican en diferentes campos de la ciencia, tal como la bioingeniería, seguridad electrónica y otras.</p>	<p>Objetivo general</p> <p>El objetivo general del presente trabajo de investigación es diseñar un modelo Neuronal para el reconocimiento de Imágenes y Color, que nos ayudarán a distinguir y optimizar la selección de los objetivos con mayor fiabilidad.</p> <p>Objetivo específico</p> <p>El objetivo específico del presente trabajo es estudiar el problema de segmentación de las señales y estudiar los principios de funcionamiento de una red neuronal ARTMAP y la respuesta de los filtros orientados y difusiones cromáticas.</p>	<p>“El diseño mejora la fiabilidad del reconocimiento de imágenes y color”.</p>	<p>Variable dependiente:</p> <p>❖ La fiabilidad del reconocimiento de imágenes y color.</p> <p>Variable independiente:</p> <p>Diseño de un Modelo Neuronal.</p>	<p>Materiales</p> <p>Entre los materiales que se utilizaron en la investigación podemos anotar: Laptop perfil 7, programa MATLAB, Visual C++, y Microsoft Office.</p> <p>Métodos</p> <p>Se diseña el modulo del sistema de color oponente COS. Se diseña el módulo del Sistema Cromático Segmentador CSS .Se ensamblan los módulos, y crean las interfaces. Se prueba el modelo propuesto en el trabajo de investigación. Se comparan los resultados obtenidos con el modelo Canny.</p>

Handwritten signature