

# Diseño Automático de Operadores Morfológicos Aplicado a la Segmentación de Angiografías Retinales.

**Benalcázar M.<sup>1,2</sup>, Padín J.<sup>1,2</sup>, Bouchet A.<sup>1,2</sup>, Brun M.<sup>1</sup> y Ballarin V.<sup>1</sup>**  
*<sup>1</sup>Laboratorio de Procesos y Medición de Señales, Departamento de Electrónica, Facultad de Ingeniería, Universidad Nacional de Mar del Plata, Buenos Aires, Argentina. <sup>2</sup>Consejo Nacional de Investigaciones Científicas y Técnicas (CONICET)*

## Resumen

*El diseño automático de operadores morfológicos, mediante aprendizaje computacional, surge ante las múltiples dificultades que se tienen en el diseño heurístico, el cual requiere de cierta experiencia y conocimiento técnico del usuario. En el presente trabajo se aplican los Operadores Morfológicos de Ventana, o también llamados W-operadores, diseñados mediante aprendizaje computacional, para la eliminación del ruido en imágenes de angiografías retinales, previamente segmentadas utilizando Morfología Matemática Difusa. Los resultados obtenidos mostraron una reducción del nivel de ruido, lo cual mejora la calidad de la segmentación y facilita al especialista la interpretación de la información contenida en dichas imágenes.*

## Palabras Clave

Operadores Morfológicos, Operadores Morfológicos de Ventana, Aprendizaje computacional, Morfología Matemática Difusa.

## 1. Introducción

La angiografía retinal es un examen diagnóstico que usa cámaras fotográficas especiales para evaluar las estructuras del fondo ocular. Para realizar este examen se administran gotas oculares que hacen dilatar la pupila para luego tomar fotografías del interior del ojo. Después de tomar el primer grupo de imágenes, se inyecta un tinte especial, llamado fluoresceína, dentro de la vena. Una cámara especial toma fotografías del ojo a medida que el tinte va pasando a través de los vasos sanguíneos en la parte posterior del ojo. Este examen se utiliza para detectar fugas o daños en los vasos sanguíneos de la retina. También se puede usar para diagnosticar problemas oculares o para determinar qué tan bien está funcionando un tratamiento [6,7].

Una de las tareas más importantes en el análisis de las angiografías retinales es la detección y segmentación de los vasos sanguíneos presentes, a partir de lo cual es posible detectar anomalías y/o daños. Para ello pueden utilizarse diferentes algoritmos, con variado nivel de éxito [5,8,9]. En general dichos algoritmos son de diseño heurístico, basado en conocimiento a priori del problema (en este caso la detección de líneas irregulares), y se definen como combinación y sucesión de filtros locales y globales [8].

En este trabajo se propone el uso de Operadores Morfológicos de Ventana como etapa final de la segmentación de vasos sanguíneos en imágenes de angiografías retinales, diseñados estadísticamente a partir de ejemplos. De esta forma, además de la heurística, se utiliza también el conocimiento de un experto por medio de imágenes segmentadas manualmente.

### 1.1. Operadores Morfológicos de Ventana

Una imagen binaria puede modelarse como una función  $h: E \rightarrow \{0,1\}$ , donde  $E$  puede ser los planos  $\mathbb{R}^2$ ,  $Z^2$ , o un subconjunto finito o infinito de ellos [1,2,3]. En nuestro caso particular asumimos que  $E$  es un subconjunto rectangular de  $Z^2$ . Un punto  $t$  de dicha imagen es una coordenada en  $E$ , de la forma  $t = (x, y)$  con  $x$  e  $y$  números enteros. Finalmente, una *ventana*  $W$  es otro subconjunto pequeño de  $Z^2$ , usualmente incluyendo el origen:  $(0,0) \in W$ . Sea  $h$  una imagen binaria,  $t$  un punto arbitrario de dicha imagen y  $W$  una ventana donde  $W = \{w_1, w_2, \dots, w_n\}$ , siendo  $w_k$ ,  $k = 1, \dots, n$ , los elementos (puntos) de  $W$ , denotando también  $n = |W|$ . Una *configuración* es una observación  $\mathbf{u}_{h(t)}$  de la imagen  $h$  por  $W$  en el punto  $t$ , y se compone de los valores de la imagen en una vecindad de  $t$  definida por  $W$ . Formalmente,  $\mathbf{u}_{h(t)} = (u_1, \dots, u_n)$  es un vector de  $n$  valores binarios,  $u_k \in \{0,1\}$ , cuyos valores están definidos por  $u_k = h(t + w_k)$ , o sea, el valor de la imagen en el punto " $w_k$ " de la ventana después de trasladarla por  $t$ , con lo cual  $\mathbf{u}_{h(t)}$  puede escribirse como:

$$\mathbf{u}_{h(t)} = (h(w_1 + t), h(w_2 + t), \dots, h(w_n + t)) \quad (1)$$

Como cada configuración  $\mathbf{u}_{h(t)}$  es un vector de  $n$  valores binarios, la cantidad posible de configuraciones para una ventana  $W$  de  $n$  elementos es  $2^n$ .

Los *Operadores Morfológicos de Ventana*  $\Psi$ , o también llamados *W-operadores* [1], son funciones que se aplican a imágenes y generan otras imágenes de la forma  $\Psi: \{0,1\}^E \rightarrow \{0,1\}^E$ . Así, si  $h$  es una imagen binaria sobre  $E$ , y  $g = \Psi(h)$ , entonces  $g$  es también una imagen binaria sobre  $E$ , definida por  $g(t) = \Psi(h)(t)$ . Estos operadores se caracterizan mediante funciones binarias, llamadas *funciones características*, de la forma  $\psi: \{0,1\}^n \rightarrow \{0,1\}$ , con lo cual para cada punto  $t \in E$ :

$$g(t) = \Psi(h)(t) = \psi(h(w_1 + t), h(w_2 + t), \dots, h(w_n + t)) = \psi(\mathbf{u}_{h(t)}) \quad (2)$$

Los W-operadores cumplen con dos propiedades muy importantes: *invariancia por traslación* y *localmente definidos dentro de W* [4]. La primera propiedad se cumple para un operador  $\Psi$  si  $\Psi(h_t) = \Psi(h)_t$  para cualquier punto  $t$ . La segunda propiedad se cumple para un operador si  $\Psi(h)_t = \Psi(h \cap W_t)_t$  para todo punto  $t$ , donde  $W_t$  es la traslación de  $W$  por  $t: W_t = \{w + t: w \in W\}$ . La segunda propiedad indica que sólo se requiere conocer los valores de  $h$  dentro de un entorno  $W_t$  para determinar el valor de la imagen  $\Psi(h)$  en el punto  $t$ .

### 1.2. Diseño automático de W-operadores

El diseño estadístico de W-operadores se aplica sobre pares de imágenes aleatorias. Usualmente una imagen binaria  $h$  es una *realización* de un proceso aleatorio  $H$ . Un problema clásico de diseño se presenta cuando existen dos procesos aleatorios de imágenes, no independientes, llamados por ejemplo  $I$  y  $O$ , donde  $I$  es el proceso que genera imágenes "ideales" y  $O$  es el proceso que genera imágenes "observadas". Los pares  $(I, O)$  están altamente correlacionados. Por ejemplo, el proceso  $I$  puede generar

imágenes de figuras geométricas, y el proceso  $\mathbf{O}$  generar las mismas imágenes rellenas. Puede ser también que  $\mathbf{O}$  genere las mismas imágenes que  $\mathbf{I}$  más un agregado de ruido aleatorio. En todos los casos, el objetivo del diseño es encontrar un W-operador  $\Psi$  que, dado realizaciones  $(I, O)$  del par  $(\mathbf{I}, \mathbf{O})$ ,  $\Psi(O)$  sea lo más aproximado posible a  $I$  [2].

La calidad del operador  $\Psi$  está medida por  $\varepsilon(\Psi)$ , la esperanza (relativa a la distribución conjunta de  $\mathbf{I}$  y  $\mathbf{O}$ ) de la distancia entre la imagen ideal y la imagen obtenida por la aplicación de  $\Psi$  sobre la imagen observada:

$$\varepsilon(\Psi) = E[D(I, \Psi(O))], \quad (3)$$

Donde  $D$  es definida como la media de una medida de distancia puntual  $d$ , esto es:

$$D(I, \Psi(O)) = \frac{1}{|E|} \sum_{t \in E} d(I(t), \Psi(O)(t)) \quad (4)$$

Siendo  $|E|$  igual a la cantidad de píxeles de las imágenes bajo análisis.

Si se asume  $d(z, z') = (z - z')^2$ , entonces  $\varepsilon(\Psi)$  es el *Error Cuadrático Medio* (ECM) de  $\Psi$  para el par  $(\mathbf{I}, \mathbf{O})$ , el cual indica el porcentaje de píxeles que difieren entre las imágenes  $I$  y  $\Psi(O)$ , con lo cual la ecuación (4) puede escribirse de la siguiente manera:

$$\varepsilon(\Psi) = E \left[ \frac{1}{|E|} \sum_{t \in E} (I(t) - \Psi(O)(t))^2 \right]. \quad (5)$$

Por lo tanto, dado un modelo para las imágenes aleatorias observadas e ideales, el diseño automático de estos operadores morfológicos consiste en encontrar un operador  $\Psi$  que minimice el ECM dado por la ecuación (5). En el contexto de W-operadores, el problema consiste en encontrar la función característica  $\psi$  que define el W-operador  $\Psi$  que minimiza la ecuación (5). Considerando que la distribución conjunta del par  $(\mathbf{I}, \mathbf{O})$  es *estacionaria*, entonces este problema se reduce a minimizar el siguiente error, calculado en el origen (0,0) [1]:

$$\varepsilon(\psi) = E \left[ (I(0) - \psi(O|_W))^2 \right] \quad (6)$$

En términos del ECM, la ecuación (6) puede expresarse de la siguiente manera:

$$ECM = \sum_{\mathbf{u} \in I \cap W_{(0,0)}} P(I(0) \neq \psi(\mathbf{u}) | \mathbf{u}) P(\mathbf{u}) \quad (7)$$

Donde  $P(I(0) \neq \psi(\mathbf{u}) | \mathbf{u})$  representa la probabilidad condicional, dada la observación  $\mathbf{u}$ , de que  $I$  sea diferente al resultado de aplicar la función característica  $\psi$ , del W-operador  $\Psi$ , a una observación  $\mathbf{u}$  de la imagen  $O$  en el origen de coordenadas, mientras que  $P(\mathbf{u})$  es la probabilidad con la que aparece esta observación.

Dado que  $\psi(\mathbf{u}) \in \{0,1\}$ , entonces la ecuación (7) puede escribirse como:

$$ECM = \sum_{\mathbf{u}: \psi(\mathbf{u})=0} P(I(0) \neq \psi(\mathbf{u}) | \mathbf{u}) P(\mathbf{u}) + \sum_{\mathbf{u}: \psi(\mathbf{u})=1} P(I(0) \neq \psi(\mathbf{u}) | \mathbf{u}) P(\mathbf{u}) \quad (8)$$

La ecuación anterior equivale a:

$$ECM = \sum_{\mathbf{u}: \psi(\mathbf{u})=0} P(I(0)=1 | \mathbf{u}) P(\mathbf{u}) + \sum_{\mathbf{u}: \psi(\mathbf{u})=1} P(I(0)=0 | \mathbf{u}) P(\mathbf{u}) \quad (9)$$

Por lo tanto, el W-operador óptimo  $\Psi_{opt}$ , con función característica  $\psi_{opt}$ , es aquel que minimiza la ecuación (9). Formalmente  $\psi_{opt}$  queda definido de la siguiente manera:

$$\psi_{opt} \begin{cases} \psi(\mathbf{u})=1 & \text{si } P(I(0)=1 | \mathbf{u}) > P(I(0)=0 | \mathbf{u}) \\ \psi(\mathbf{u})=0 & \text{si } P(I(0)=1 | \mathbf{u}) < P(I(0)=0 | \mathbf{u}) \end{cases} \quad (10)$$

Los W-operadores son importantes para el diseño automático debido a que la función característica  $\psi_{opt}$ , que minimiza error dado por la ecuación (9) se puede estimar a partir de ejemplos de pares de observación de la forma  $(\mathbf{u}_{h(t)}, \psi(\mathbf{u}_{h(t)}))$ . La función característica obtenida  $\psi_{opt}$  define un W-operador  $\Psi_{opt}$ , que minimiza el error dado por la ecuación (5) [1].

En base a lo expuesto anteriormente, el diseño automático de W-operadores consiste en encontrar una función característica  $\psi_{opt}$ , que define un W-operador  $\Psi_{opt}$ , por medio de la minimización del error (ecuación 9), estimado a partir de uno o más pares de imágenes de ejemplo, compuestos de una imagen ideal  $I$  y una imagen observada  $O$ . Esta tarea se denomina *aprendizaje computacional*, en cuyo contexto a los pares de imágenes de ejemplo se los denomina *imágenes de entrenamiento*. Esta estimación puede requerir una alta demanda de almacenamiento y cálculos, dado que el número de posibles funciones características sobre una ventana  $W$  de  $n$  elementos es  $2^{2^n}$ .

Las funciones características definidas sobre una ventana  $W$  se pueden representar, en su forma más directa, mediante una tabla con los  $2^n$  pares configuración-clase  $(\mathbf{u}, i)$  con  $i \in I$ .

El diseño automático implementado en el presente trabajo, consiste en determinar los valores de clase (0 o 1) que deben ser asignados a cada configuración para definir el operador óptimo. El proceso consta de dos etapas. En la primera etapa se recorre la ventana de observación  $W$  a lo largo de cada píxel de las imágenes de entrenamiento, con lo cual se arma una tabla que contiene las frecuencias  $frec(\mathbf{u}, i)$  para los pares  $(\mathbf{u}, i)$  que están presentes en las imágenes (Figura 1).

0	0	0	1	1	1	0	0	0
0	1	0	0	1	1	0	0	0
0	0	0	1	1	1	0	1	0
0	0	0	0	1	0	0	0	0
0	0	0	1	1	1	0	0	0
1	1	1	1	1	1	1	0	1
1	1	1	1	1	1	1	1	1
1	0	1	1	0	1	1	1	1
1	0	1	1	0	1	1	1	1
0	0	0	1	1	1	0	0	0
0	0	0	1	1	1	0	0	0
0	1	0	1	1	1	0	1	0
0	0	0	0	1	1	0	0	0
0	0	0	1	1	1	0	0	0

**Imagen observada**

$$\mathbf{u} = (0,0,1,0,1,1,1,1,1)$$

0	0	0	1	1	1	0	0	0
0	0	0	1	1	1	0	0	0
0	0	0	1	1	1	0	0	0
0	0	0	1	1	1	0	0	0
0	0	0	1	1	1	0	0	0
1	1	1	1	1	1	1	1	1
1	1	1	1	1	1	1	1	1
1	1	1	1	1	1	1	1	1
1	1	1	1	1	1	1	1	1
1	1	1	1	1	1	1	1	1
0	0	0	1	1	1	0	0	0
0	0	0	1	1	1	0	0	0
0	0	0	1	1	1	0	0	0
0	0	0	1	1	1	0	0	0
0	0	0	1	1	1	0	0	0

**Imagen ideal**

$$i = 1$$

$$W = \begin{matrix} \begin{matrix} w_1 & w_2 & w_3 \\ w_4 & w_5 & w_6 \\ w_7 & w_8 & w_9 \end{matrix} \end{matrix}$$

**Ventana de observación**

**Figura 1.** Ejemplo del proceso de obtención de frecuencias para el diseño de un W-operador  $\Psi$  con una ventana de 3x3 elementos

Dichas frecuencias son simplemente una cuenta de cuantas veces aparece la configuración  $\mathbf{u}$  en la imagen observada, acompañada del valor  $i$  en la imagen ideal. La Tabla 1 muestra un ejemplo de una tabla de frecuencias para una ventana de 3x3 elementos. En este caso existen  $2^{3 \times 3} = 2^9$  posibles configuraciones  $\mathbf{u}_0, \dots, \mathbf{u}_{255}$ .

**Tabla 1.** Ejemplo de una tabla de frecuencias para una ventana de 3x3

$\mathbf{u}_k = (u_{k1}, u_{k2}, u_{k3}, u_{k4}, u_{k5}, u_{k6}, u_{k7}, u_{k8}, u_{k9})$	$frec(\mathbf{u}_k, 0)$	$frec(\mathbf{u}_k, 1)$
$\mathbf{u}_0 = (0,0,0,0,0,0,0,0,0)$	$frec(\mathbf{u}_0, 0)$	$frec(\mathbf{u}_0, 1)$
$\mathbf{u}_1 = (0,0,0,0,0,0,0,0,1)$	$frec(\mathbf{u}_1, 0)$	$frec(\mathbf{u}_1, 1)$
$\vdots$	$\vdots$	$\vdots$
$\mathbf{u}_{255} = (1,1,1,1,1,1,1,1,1)$	$frec(\mathbf{u}_{255}, 0)$	$frec(\mathbf{u}_{255}, 1)$

En la Tabla 1, los valores  $frec(\mathbf{u}_k, i)$ , previa normalización por la cantidad total de observaciones, son estimadores de la probabilidad conjunta de encontrar un píxel con valor  $i$ ,  $i \in \{0,1\}$ , en la imagen  $I$  y la configuración  $\mathbf{u}_k$  de la imagen  $O$ .

El segundo paso consiste en determinar el valor más frecuente  $\max(frec(\mathbf{u}, 0), frec(\mathbf{u}, 1))$  para cada configuración  $\mathbf{u}$ , el cual según la ecuación (9) permite determinar el valor de la función característica óptima  $\psi(\mathbf{u})$  para dicha observación. Este paso produce una tabla, o mapeo, que representa la función característica  $\psi$  del W-operador diseñado. La Tabla 2 muestra un ejemplo de la tabla que representa el mapeo de un W-operador diseñado con una ventana de 3x3.

**Tabla 2.** Ejemplo de un mapeo de un W-operador  $\Psi$  para una ventana de 3x3

$\mathbf{u}_k = (u_{k1}, u_{k2}, u_{k3}, u_{k4}, u_{k5}, u_{k6}, u_{k7}, u_{k8}, u_{k9})$	$\psi(\mathbf{u}_k)$
$\mathbf{u}_0 = (0,0,0,0,0,0,0,0,0)$	1
$\mathbf{u}_1 = (0,0,0,0,0,0,0,0,1)$	0
$\vdots$	$\vdots$
$\mathbf{u}_{255} = (1,1,1,1,1,1,1,1,1)$	1

En la práctica pueden darse casos donde  $frec(\mathbf{u},0) = frec(\mathbf{u},1)$  para una determinada configuración, en cuyo caso se utiliza alguna heurística, por ejemplo asignar un valor 0 a la función característica para dicha observación:  $\psi(\mathbf{u}) = 0$ . También puede suceder que una vez que se ha recorrido la ventana  $W$ , a lo largo de cada píxel de las imágenes de entrenamiento, no se tengan datos de frecuencia para una determinada configuración, lo que equivale a decir que el operador no ha aprendido el valor de salida para dicha configuración, en cuyo caso podemos utilizar otra heurística, por ejemplo la de asignar el valor 0 o 1 más frecuente en la imagen ideal.


### 1.3. Análisis con ruido sintético

#### 1.3.1. Análisis del error en función de la cantidad de datos de entrenamiento

Como paso previo a la aplicación, se realizaron simulaciones para estudiar el comportamiento de los operadores diseñados estadísticamente. Se analizó la calidad de los operadores obtenidos a través del aprendizaje computacional en función de la cantidad de datos de entrenamiento, en un contexto de ruido aleatorio sintético.

Para dicho análisis se utilizaron imágenes de la base de datos DRIVE, la cual contiene imágenes en color de angiografías retinales y sus correspondientes gold estándar. Estas últimas son imágenes binarias formadas por los vasos sanguíneos, cuya segmentación fue realizada manualmente con la ayuda de expertos [8]. En este caso se trabajó directamente con las imágenes de gold estándar como imágenes ideales, y se añadió ruido puntual a dichas imágenes para definir las imágenes observadas. Con estos pares de imágenes se diseñaron W-operadores con la función de eliminar el ruido agregado. Algunas de las imágenes fueron usadas como imágenes de entrenamiento y otras como imágenes de testeo.


En el gráfico de la Figura 2 se puede observar que para ventanas de 3x3 y diferentes porcentajes de ruido, el ECM se estabiliza más rápidamente que para la ventana de 5x5. Esto se debe a que la cantidad máxima de configuraciones posibles para los operadores  $\Psi$  es de  $2^9$  y de  $2^{25}$ , respectivamente. Por lo tanto, en este último caso hay muchas más posibilidades de configuraciones que se deben aprender, razón por la cual se necesita una mayor cantidad de puntos para completar dicho aprendizaje con respecto a la cantidad de puntos usados en el primer caso. Este hecho también repercute en el incremento del tiempo de procesamiento (costo computacional) para ventanas de 5x5 comparado con ventanas de 3x3.




**Figura 2.** ECM en función del número de píxeles de entrenamiento para ventanas de 3x3 y 5x5

Para ventanas de 3x3 el aprendizaje se completa con aproximadamente  $10^5$  puntos de entrenamiento; es decir, una sola imagen cuya cantidad promedio de píxeles equivale a  $3.30 \times 10^5$  es suficiente para el entrenamiento. Para ventanas de 5x5 es evidente que se requieren más de dos imágenes para completar el aprendizaje por la gran cantidad de configuraciones de  $\Psi$ .

A manera de ejemplo, en las Figuras 3 y 4 se puede apreciar el efecto de aplicar W-operadores, obtenidos a partir de diferentes cantidades de píxeles de entrenamiento.



**Figura 3.** Resultados de procesar una imagen (a) con un ruido sintético inicial de 10% mediante la aplicación de un W-operador diseñado a partir de una ventana de 3x3 y con: (b)  $1.75 \times 10^4$  puntos de entrenamiento (ECM = 2.40%), (c)  $3.17 \times 10^4$  puntos de entrenamiento (ECM = 2.36%) y (d)  $6.60 \times 10^5$  puntos de entrenamiento (ECM = 2.34%)



**Figura 4.** Resultados de procesar una imagen (a) con un ruido sintético inicial de 15% mediante la aplicación de un W-operador diseñado a partir de una ventana de 5x5 y con: (b)  $8.25 \times 10^4$  puntos de entrenamiento (ECM = 12.23%), (c)  $3.30 \times 10^5$  puntos de entrenamiento (ECM = 11.74%) y (d)  $6.60 \times 10^5$  puntos de entrenamiento (ECM = 11.17%)

### 1.3.2. Análisis del error en función de la cantidad de ruido sintético

En esta etapa se analizó la calidad de los W-operadores diseñados a partir de imágenes con diferentes niveles de ruido. Se seleccionaron 20 imágenes de gold estándar como imágenes ideales, y las imágenes observadas se obtuvieron añadiendo diferentes porcentajes de ruido puntual a las imágenes ideales. El diseño del operador, en cada caso, se realizó con una ventana de 3x3 y utilizando sólo una imagen de entrenamiento, mientras que las restantes 19 imágenes (con igual porcentaje de ruido) fueron utilizadas para testeo.

Para cada grupo se calculó el ECM entre las imágenes resultantes y las ideales, el promedio de dichos valores y su correspondiente desviación estándar. Los resultados obtenidos se vuelcan en la Tabla 3.

**Tabla 3.** Resultados de aplicar los W-operadores a 5 grupos de imágenes con distintos niveles de ruido

Ruido inicial promedio [%]	Ruido final promedio [%]	Desviación estándar de ruido final [%]	Proporción de disminución del ruido[%]
5	0.89	0.08	82.20
10	1.98	0.21	80.20
15	3.39	0.30	77.40
20	4.87	0.36	75.65
25	6.94	0.47	72.24

Analizando los datos de la columna *Ruido final promedio* se puede decir que la aplicación de los W-operadores, a cada imagen de los 5 grupos de trabajo, hizo que disminuya notablemente su nivel ruido. Por otro lado, la columna *Desviación estándar* evidencia que la disminución del ruido fue en proporciones similares para todas las



imágenes de un mismo grupo. También se puede observar en la columna *Proporción de disminución del ruido* que cuando el ruido inicial de las imágenes a procesar es bajo, la mejora es más significativa comparado con los resultados obtenidos para imágenes con alto ruido inicial.

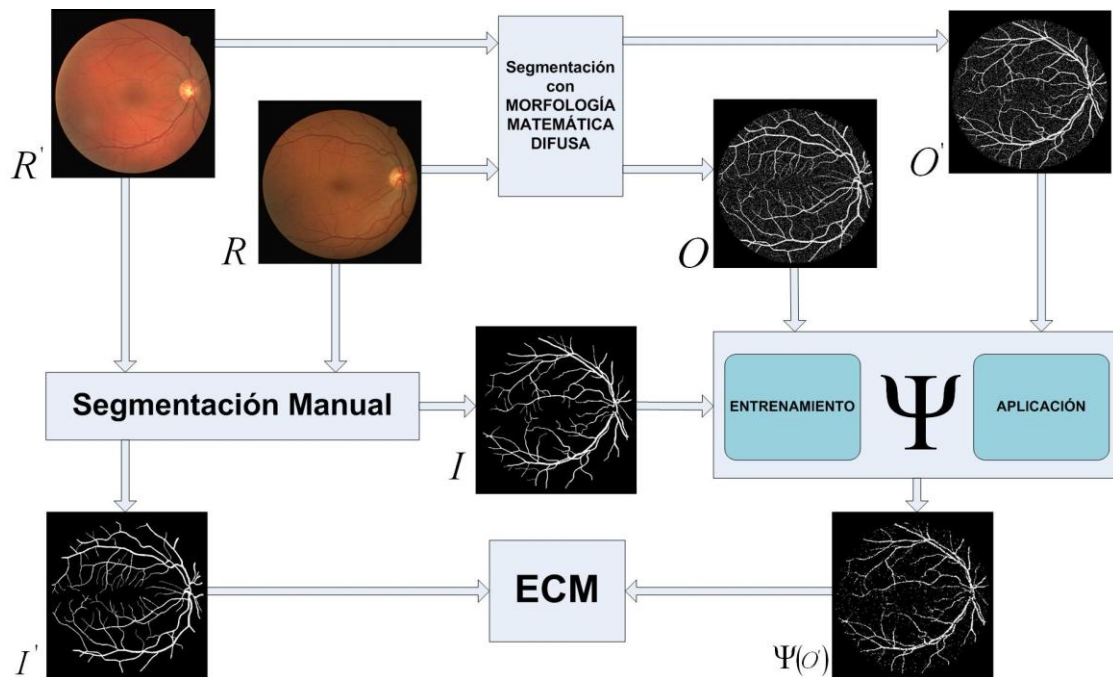
### 1.3.3. Aplicación a la segmentación de angiografías

El último paso en este trabajo es el de estudiar el diseño automático de W-operadores en un ejemplo de aplicación con datos reales (no sintéticos). El caso ejemplo es el de segmentación de vasos sanguíneos en angiografías retinales, el cual ha sido abordado por diferentes heurísticas [5,9]. El problema clásico consiste en obtener una imagen binaria, donde están definidos los vasos sanguíneos, a partir de una imagen color de una angiografía de retina. En este contexto, aplicamos el diseño estadístico como una corrección de la imagen resultante de la segmentación por medios heurísticos.

## 2. Metodología

Para analizar el uso del diseño estadístico de W-operadores en la segmentación de imágenes de angiografías, se decidió aplicar una mejora, diseñada estadísticamente, al resultado de la segmentación heurística definida en [5], donde los vasos sanguíneos son segmentados mediante el uso de operadores de imágenes basados en Morfología Matemática Difusa (MMD). Esta mejora consiste en un W-operador  $\Psi$ , el cual se aplica sobre la imagen binaria resultante de la segmentación, y que debería eliminar pequeños artefactos o discontinuidades resultantes de una segmentación imperfecta.

Como pares de imágenes de entrenamiento, para diseñar estadísticamente el W-operador  $\Psi$ , se utilizaron las imágenes binarias resultantes del algoritmo definido en [5] (como imágenes observadas) y las imágenes de gold estándar asociadas a dichas imágenes (como imágenes ideales), tomadas de la base de datos DRIVE.



**Figura 5.** Esquema de trabajo para el diseño automático, aplicación y evaluación de W-Operadores para la mejora en la segmentación de imágenes de angiografías retinales

La segmentación heurística de los vasos sanguíneos se realizó a través de la aplicación de operadores de la MMD. Los resultados de dicha segmentación son lo que deben ser mejorados por medio de los W-operadores diseñados estadísticamente. La Figura 5 muestra un esquema del procedimiento utilizado en el presente trabajo para el diseño, aplicación y evaluación de dichos operadores. Las imágenes de ejemplo son separadas en dos conjuntos: imágenes de entrenamiento, utilizadas para diseñar los operadores, e imágenes de testeo, utilizadas para estimar el error de los operadores resultantes.


En la Figura 5,  $R$  y  $R'$  representan las imágenes de angiografías en color,  $I$  e  $I'$  sus correspondientes imágenes segmentadas manualmente por un experto, a las que llamamos imágenes ideales.  $O$  y  $O'$  son imágenes que se obtienen al aplicar el algoritmo de segmentación.  $O$  es la imagen de entrenamiento,  $O'$  la imagen para testeo y  $\Psi(O')$  es la imagen resultante de aplicar el W-operador. La calidad del operador es medida a través del ECM entre  $\Psi(O')$  e  $I'$ , estimado por la ecuación (5) sobre un conjunto de pares de imágenes ( $I', O'$ ).

Para el diseño automático de los W-operadores se utilizaron tanto uno y dos pares de imágenes de entrenamiento con una ventana de 3x3. Estos parámetros fueron seleccionados en base al análisis presentado en la sección 1.3.

### 3. Resultados

En esta sección se presentan los resultados obtenidos de aplicar el diseño automático de los W-operadores, mediante aprendizaje computacional, para la eliminación de ruido en imágenes de angiografías retinales segmentadas aplicando MMD.

En la Figura 6 se muestra, a modo de ejemplo, el resultado de aplicar un W-operador, diseñado con uno y dos pares de imágenes de entrenamiento. Se puede apreciar que en las imágenes resultantes existe una reducción del nivel de ruido y los vasos sanguíneos se distinguen con mayor claridad que en la imagen original.



**Figura 6.** Imagen original (ECM = 7.90%) (a) y resultados de aplicar el W-operador diseñado con: (b) un par de imágenes de entrenamiento (ECM = 6.4%) y (c) dos pares de imágenes de entrenamiento (ECM = 6.64%)

Finalmente, la aplicación de los W-operadores diseñados con un par de imágenes de entrenamiento produjo una reducción promedio del ECM de 13.43%, mientras que cuando se emplearon dos pares de imágenes de entrenamiento, la reducción promedio del ECM fue de 13.37%.

#### 4. Conclusión

Las imágenes resultantes de aplicar la segmentación con MMD contienen los vasos sanguíneos (gruesos y delgados), más un cierto nivel de ruido con características muy similares a las de un ruido puntual. Este ruido no permite que se distingan con claridad los vasos sanguíneos delgados, lo cual dificulta la interpretación de estas imágenes. La aplicación de los  $W$ -operadores, diseñados mediante aprendizaje computacional, produjo una disminución del ruido presente en dichas imágenes, lo cual se pudo corroborar a través la disminución del ECM en todas las imágenes procesadas. La proporción de reducción del ECM fue similar tanto para el caso en que el aprendizaje se realizó con un solo par de imágenes como para cuando se emplearon dos pares de imágenes de entrenamiento.

#### Referencias

- [1] Hirata R., Brun M., Barrera J. y Dougherty E.; “Advances in Nonlinear Signal and Image Processing”; Capítulo 2; páginas 15-16 ;Ed Hindawi Publishing Corporation 2006.
- [2] Barrera J., Dougherty E., Brun M.; “Hybrid human-machine binary morphological operator design. An independent constraint approach”; Elsevier Signal Processing; 2000; pp. 1469-1487.
- [3] Hirata R., Brun M., Barrera J., Dougherty E.; “Image Restoration by Multiresolution Non-linear Filters”; Proceedings of SPIE; 2001; vol. 4304.
- [4] Barrera J., Brun M.; “Translation invariant transformations of discrete random sets”; Anais do XI SIBGRAP; International Symposium on Computer Graphics, Image Processing, and Vision; 2008.
- [5] Bouchet A., Brun M., Ballarin V.; “Morfología Matemática Difusa aplicada a la segmentación de angiografías retinales”; Revista Argentina de Bioingeniería; Junio 2010; vol. 16; No. 1; pp. 7-10.
- [6] Spaeth GL. “Fluorescein angiography: Its contributions toward understanding the mechanisms of visual loss in glaucoma”; Trans Am Ophthalmol Soc 1975;73:491-553.
- [7] Schmetterer L, Garhofer G; “How can blood flow be measured?”; Surv Ophthalmol;52 Suppl 2:S134-8. November 2007.
- [8] J.J. Staal, M.D. Abramoff, M. Niemeijer, M.A. Viergever, B. van Ginneken; "Ridge based vessel segmentation in color images of the retina"; IEEE Transactions on Medical Imaging; 2004; vol. 23, pp. 501-509.
- [9] Salvatelli.A, Bizai,G;Drozdowicz,B.;Delrieux,C; "Clasificador de Retinopatías Diabéticas en Imágenes de fondo ocular utilizando la pendiente espectral multifractal"; CAIS 2010, Congreso Argentino de Informática y Salud, en la 39 JAIIO, Jornadas Argentinas de Informática, Buenos Aires, 30 de Agosto al 3 de Septiembre de 2010.

#### Contacto:

*Dra. Virginia Ballarin. Laboratorio de Procesos y Medición de Señales – Departamento de Electrónica – Facultad de Ingeniería – Universidad Nacional de Mar del Plata: [vballari@fi.mdp.edu.ar](mailto:vballari@fi.mdp.edu.ar)*