

PONTIFICIA UNIVERSIDAD CATÓLICA DEL PERÚ

FACULTAD DE CIENCIAS E INGENIERÍA



**PONTIFICIA
UNIVERSIDAD
CATÓLICA
DEL PERÚ**

**Caracterización y clasificación automática de ríos en
imágenes satelitales**

**Tesis para optar el Título de Ingeniero Informático, que presenta
el bachiller:**

Kevin Brown Manrique

Asesor: Dr. César Armando Beltrán Castañón

Lima, junio del 2017

Dedicado a mi madre María Teresa Manrique Negrón, por apoyarme en todo momento y en cada decisión tomada, por estar siempre pendiente a lo que necesitara y por siempre esforzarse arduamente en sacarnos a mí y a mi hermano adelante.



Agradecimientos

A mi asesor, el Dr. César Beltrán Castañón por aconsejarme y brindarme su apoyo siempre en el desarrollo de todo el proyecto.

A mis tías, Diana Inga y Norma Noriega, quienes me ayudaron en todo momento a lo largo de la carrera y contribuyeron enormemente a que la pudiera finalizar.



RESUMEN

En los últimos años, el fenómeno conocido como cambio climático se está volviendo cada vez más notorio. Como resultado de este fenómeno, uno de los sectores que se verá más afectado será el de los recursos hídricos debido al impacto que se tendrá sobre el ciclo hidrológico y en los sistemas de gestión de agua, y a través de estos, en los sistemas socioeconómicos. Uno de los impactos conocidos es el conjunto de modificaciones en los patrones de precipitación y caudal de los ríos que afectarán a todos sus usuarios.

Los caudales de ríos se forman por sedimentos que han sido y están siendo transportados por agua que fluye y por lo general se pueden clasificar en 4 formas básicas: rectos, meandros, trenzados y anastomosados. Es importante el tener reconocidos los distintos ríos y para ello no basta con conocer su localización sino además tener mapeadas las características de estos según su canal aluvial. Uno de los métodos tradicionales para caracterizar la morfología de un río (anchura, sinuosidad, características de inundación, etc.) es a través de trabajo de campo, que es costoso y demanda tiempo. Estos métodos no sólo consumen tiempo, sino que además, son extremadamente difíciles de llevar a cabo debido a que están sujetos a factores como inundaciones, mareas y tormentas que pueden hacer el lugar inaccesible y peligroso para recolectar información.

El presente proyecto de fin de carrera propone una solución ante el problema de la dificultad y alto costo que supone la realización del trabajo de campo que permita caracterizar la morfología de un río. La solución planteada es una nueva técnica computacional para la caracterización automática de la morfología de los ríos, Dimensión Fractal Multi-escala, el cual aprovecha las características fractales de formación de elementos naturales como los ríos.

El proyecto inicia con un proceso de limpieza de ruido a los datos de entrada que son esqueletos de ríos, para luego, por cada uno, aplicar el método de *Crossing Number* para obtener la multiplicidad de canal. Seguidamente, se elaborará una Curva Fractal aplicando el método de Dimensión Fractal Multi-escala y de la curva obtenida se extraerán puntos de interés para generar un vector de características necesario para la clasificación. A continuación, se entrenará un clasificador empleando los vectores de características para generar un modelo predictivo. Finalmente, el modelo será evaluado mediante la clasificación de un nuevo esqueleto de río.

TEMA DE TESIS PARA OPTAR EL TÍTULO DE INGENIERO INFORMÁTICO

TÍTULO: Caracterización y clasificación automática de ríos en imágenes satelitales.

ÁREA: Ciencias de la Computación.


ASESOR: Dr. César Armando BELTRÁN CASTAÑÓN

ALUMNO: Kevin BROWN MANRIQUE

CÓDIGO: 20095513

TEMA N°: #649

FECHA: San Miguel, 16 de noviembre de 2016



DESCRIPCIÓN

Debido al cambio climático uno de los sectores que se verá más afectado será el de los recursos hídricos. Este no es un nuevo hallazgo, se dio a conocer por primera vez en la declaración final de las sesiones científicas de la Segunda Conferencia Mundial sobre el Clima, celebrada en 1990, que reconoce que: "Entre los impactos más importantes del cambio climático serán sus efectos sobre el ciclo hidrológico y en los sistemas de gestión de agua y, a través de estos, en los sistemas socioeconómicos".

Entonces muchos de los impactos previstos del cambio climático se verán realizados a través del agua. Modificaciones en los patrones de precipitación y caudal de los ríos afectarán a todos sus usuarios; aumento de la incertidumbre y el cambio de las necesidades de agua del cultivo supondrá una amenaza para los agricultores de secano (terreno de cultivo que no tiene riego y se beneficia del agua de la lluvia); intensificación de las sequías, inundaciones, tifones y monzones hará que muchas más personas se vuelvan más vulnerables.

Es por ello importante el tener reconocidos los distintos ríos y para ello no basta con conocer su localización sino además tener mapeadas las características de estos según su canal aluvial, esta caracterización morfológica de los ríos se justifica por los siguientes aspectos:

1. Predecir el comportamiento de un río de acuerdo a su apariencia.
2. Desarrollar las relaciones específicas de hidráulica y sedimentación para un determinado tipo y estado de morfología del canal.
3. Proporcionar un mecanismo de para extrapolar sitios específicos de colección de información en una determinada corriente a aquellos de similar característica.

4. Proporcionar un marco de comunicación referente, consistente y reproducible, para aquellos que trabajan en sistemas ríos y otras disciplinas relacionadas.

Uno de los métodos tradicionales para caracterizar la morfología de un río es a través de trabajo de campo, el cual es costoso, demanda tiempo y además está sujeto a factores externos como inundaciones, mareas y tormentas que pueden hacer el lugar inaccesible y peligroso para recolectar información.

El problema enfrentado es la dificultad y el alto costo que supone la realización del trabajo de campo que permita caracterizar la morfología de un río, siendo que al momento, este trabajo se realiza de forma manual por los especialistas hidrólogos. En ese sentido, el presente trabajo propone una nueva técnica computacional para la caracterización automática de la morfología de los ríos, Dimensión Fractal Multi-escala, el cual aprovecha las características fractales de formación de elementos naturales como los ríos.

OBJETIVO GENERAL

Proponer e implementar una herramienta computacional que permita la clasificación de un río en base a sus características morfológicas. La caracterización se realiza mediante el cálculo de la Dimensión Fractal Multi-escala en la secuencia de píxeles que representan el esqueleto del río, previamente detectada, en imágenes satelitales.

OBJETIVOS ESPECÍFICOS

Los objetivos específicos son:

OE1. Componer un repositorio de ríos identificados, que comprende la selección de imágenes esquelizadas de ríos, determinando las regiones de interés.

OE2. Determinar los patrones característicos mediante el análisis y selección de un conjunto de variables que determinan la forma del caudal de los ríos.

OE3. Generar el modelo de clasificación de ríos, mediante la experimentación de algoritmos de aprendizaje de máquina que se adecuen a este tipo de problema y adaptarlo calibrando parámetros (entrenamiento).

OE4. Validar el modelo de clasificación mediante técnicas de evaluación de clasificadores así como con la comprobación por parte del especialista hidrólogo.




ALCANCE

El presente proyecto, ubicado dentro del área de Ciencias de la Computación, se encuentra orientado a la investigación aplicada e implica el desarrollo de una herramienta de software que clasifique, a través del análisis de los patrones de circulación de los caudales de ríos, cuál es el río representado en una determinada imagen satelital previamente trabajada.

Esta herramienta realizará la clasificación en base a 4 canales: rectos, meandros, trezados y anastomosados ya que se cuenta con una mayor información al respecto de sus características. Para poder efectuar la clasificación anterior, la herramienta deberá previamente realizar una extracción de características que permita discernir entre una clase y las demás.

Máximo: 100 páginas



Índice General

CAPÍTULO 1: GENERALIDADES	1
1.1 PROBLEMÁTICA	1
1.2 OBJETIVO GENERAL	4
1.3 OBJETIVOS ESPECÍFICOS	4
1.4 RESULTADOS ESPERADOS	4
1.5 HERRAMIENTAS, MÉTODOS, METODOLOGÍAS Y PROCEDIMIENTOS	5
1.5.1 HERRAMIENTAS	6
1.5.2 MÉTODOS Y PROCEDIMIENTOS	7
1.6 ALCANCE	8
1.6.1 LIMITACIONES	8
1.6.2 RIESGOS	9
CAPÍTULO 2: MARCO CONCEPTUAL	10
2.1 CANALES DE RÍOS Y SU CLASIFICACIÓN	10
2.2 DESCRIPTORES DE IMÁGENES	12
2.2.1 DESCRIPTORES DE BORDES	12
2.2.2 DESCRIPTORES DE REGIONES	12
2.3 CARACTERIZACIÓN DE REGIONES EN BASE A LA MORFOLOGÍA	13
2.3.1 DILATACIÓN	13
2.3.2 EROSIÓN	13
2.4 EXTRACCIÓN DE MINUCIAS DEL ESQUELETO DE UNA IMAGEN POR <i>CROSSING</i>	14
2.5 CARACTERIZACIÓN MEDIANTE DIMENSIÓN FRACTAL MULTI-ESCALA	15
2.6 APRENDIZAJE DE MÁQUINA	16
2.6.1 APRENDIZAJE SUPERVISADO	18
2.7 MÉTODOS DE EVALUACIÓN DE RESULTADOS	21
2.7.1 VALIDACIÓN CRUZADA	21
2.7.2 <i>PERCENTAGE SPLIT</i>	22
2.7.3 MATRIZ DE CONFUSIÓN	22
2.7.4 CURVAS ROC	22
2.8 CONCLUSIÓN	24
3.1 DATOS DE TELEDETECCIÓN Y MÉTODO SBDS	25
3.2 MÉTODO BASADO EN MORFOLOGÍA MATEMÁTICA Y EXTRACCIÓN DE CARACTERÍSTICAS LINEALES	25
3.2.1 PERFILES MORFOLÓGICOS USANDO APERTURA Y CIERRE DE RUTAS	26

3.2.2	EXTRACCIÓN DE CARACTERÍSTICAS LINEALES USANDO THRESHOLDS.....	27
3.3	CARACTERIZACIÓN DEL FLUJO DE LA CORRIENTE Y LA DETECCIÓN DE CARACTERÍSTICAS USANDO UNA TRANSFORMADA WAVELET DISCRETA	28
3.4	MÉTODOS DE CLASIFICACIÓN DE RÍOS	28
3.5	CONCLUSIONES SOBRE EL ESTADO DEL ARTE.....	30
	CAPÍTULO 4: EXTRACCIÓN DE CARACTERÍSTICAS DEL ESQUELETO DE UN RÍO	31
4.1	LIMPIEZA DE RUIDO	31
4.2	DETERMINACIÓN DE MULTIPLICIDAD DE CANAL	32
4.3	EXTRACCIÓN DE CARACTERÍSTICAS EMPLEANDO MÉTODO DE DIMENSIÓN FRACTAL MULTI-ESCALA	34
	CAPÍTULO 5: CLASIFICACIÓN DE RÍOS SEGÚN CARACTERÍSTICAS OBTENIDAS	39
5.1	CLASIFICACIÓN	39
5.1.1	USANDO MATLAB.....	39
5.1.2	USANDO WEKA.....	40
5.2	EVALUACIÓN DE RESULTADOS.....	40
5.2.1	PRUEBA 1 – SVM UNO CONTRA UNO (PRECISIÓN: 87.5%).....	41
5.2.2	PRUEBA 1 – SVM UNO CONTRA EL RESTO (PRECISIÓN: 90.8%).....	41
5.2.3	PRUEBA 1 – ADABOOST CON 200 ITERACIONES (PRECISIÓN: 85%)	42
5.2.4	PRUEBA 1 – ADABOOST CON 1000 ITERACIONES (PRECISIÓN: 90%)	43
5.2.5	PRUEBA 2 – SVM UNO CONTRA UNO (PRECISIÓN: 72.5%).....	43
5.2.6	PRUEBA 2 – SVM UNO CONTRA EL RESTO (PRECISIÓN: 70.8%).....	44
5.2.7	PRUEBA 2 – ADABOOST CON 200 ITERACIONES (PRECISIÓN: 50%)	44
5.2.8	PRUEBA 2 – ADABOOST CON 1000 ITERACIONES (PRECISIÓN: 50%)	45
5.2.9	PRUEBA 3 – MULTICLASSCLASSIFIER (80%)	45
5.3	APLICACIÓN DEL MODELO PREDICTIVO.....	46
	CAPÍTULO 6: CONCLUSIONES Y TRABAJOS FUTUROS	49
6.1	CONCLUSIONES	49
6.2	TRABAJOS FUTUROS.....	50
	REFERENCIAS BIBLIOGRÁFICAS	51

Índice de Figuras

Figura 1.1. Flujo de metodología utilizada.	7
Figura 2.1. Clasificación de patrones de canales de ríos (Adaptado de: Huggett, 2007).	12
Figura 2.2. Crossing Number. (Feng Zhao & Xiaoou Tang, 2006).	14
Figura 2.3. Propiedades del pixel según Crossing Number.	15
Figura 2.4. Curva de dimensión fractal	16
Figura 2.5. Curvas de dimensión fractal para 10 nervaduras de hoja de la especie P. maliformis.	16
Figura 2.6. Efecto del parámetro de penalidad C	20
Figura 2.7. Matriz de confusión	22
Figura 2.8. Curvas ROC para los clasificadores A y B.....	23
Figura 3.1. Perfil morfológico de un pixel típico de río.....	27
Figura 4.1. Imagen de un río meandro (izquierda) y su Esqueletización (derecha)...	31
Figura 4.2. Limpieza previa a la caracterización del esqueleto del río.	32
Figura 4.3. Bosquejo del esqueleto de un río con una bifurcación presente.....	33
Figura 4.4. Constitución de pixeles de la Figura 4.3. La celda marcada indica la bifurcación.....	33
Figura 4.5. Nueva matriz que contiene los valores CN por cada pixel.....	34
Figura 4.6. Dilatación de Figura 4.3 empleando una distancia = 7.....	35
Figura 4.7. Matriz que representa a la Figura 4.2 y la distancia entre cada pixel activo con el resto	36
Figura 4.8. Curva que representa en el eje $x = \log(d)$ y en el eje $y = \log(A(d))$	37
Figura 4.9. Curva que representa la dimensión fractal para una muestra de 40 esqueletos de ríos meandros, 40 esqueletos de ríos rectos y 40 esqueletos de ríos multicanal, en el eje $x = N \log(d)$ es la normalización de $\log(d)$ y en el eje $y =$ la forma derivada de $\log(A)$ por $\log(d)$	38
Figura 5.1. Matriz de confusión prueba 1- SVM uno contra uno	41
Figura 5.2. Matriz de confusión prueba 1- SVM uno contra el resto.....	42
Figura 5.3. Matriz de confusión prueba 1- Adaboost con 200 iteraciones	42
Figura 5.4. Matriz de confusión prueba 1- Adaboost con 1000 iteraciones	43
Figura 5.6. Matriz de confusión prueba 2- SVM uno contra uno	44
Figura 5.7. Matriz de confusión prueba 2- SVM uno contra el resto.....	44
Figura 5.8. Matriz de confusión prueba 2- Adaboost con 200 iteraciones	45
Figura 5.9. Matriz de confusión prueba 2- Adaboost con 1000 iteraciones	45
Figura 5.10. Matriz de confusión prueba 3- MultiClassClassifier	46
Figura 5.11. Imagen de un río meandro (izquierda) y su Esqueletización (derecha). 47	
Figura 5.12. Predicción hecha por el modelo desarrollado. Se clasificó correctamente un río de tipo meandro.	48

CAPÍTULO 1: GENERALIDADES

1.1 Problemática

Debido al cambio climático uno de los sectores que se verá más afectado será el de los recursos hídricos. Este no es un nuevo hallazgo, se dio a conocer por primera vez en la declaración final de las sesiones científicas de la Segunda Conferencia Mundial sobre el Clima, celebrada en 1990, que reconoce que: "Entre los impactos más importantes del cambio climático serán sus efectos sobre el ciclo hidrológico y en los sistemas de gestión de agua y, a través de estos, en los sistemas socioeconómicos" (Sadoff, Claudia & Muller, Mike. 2009).

Entonces muchos de los impactos previstos del cambio climático se verán realizados a través del agua. Modificaciones en los patrones de precipitación y caudal de los ríos afectarán a todos sus usuarios; aumento de la incertidumbre y el cambio de las necesidades de agua del cultivo supondrá una amenaza para los agricultores de secano (terreno de cultivo que no tiene riego y se beneficia del agua de la lluvia); intensificación de las sequías, inundaciones, tifones y monzones hará que muchas más personas se vuelvan más vulnerables (Sadoff, Claudia & Muller, Mike. 2009).

Algunos de estos impactos se verán reflejados en el rol del agua en todas las vidas. Por lo tanto la agricultura de secano tendrá que adaptarse a los nuevos patrones de precipitaciones. Los sistemas de salud tendrán que hacer frente a los cambios en la incidencia de enfermedades, como el cólera y la malaria, debido a cambios en la ecología. Infraestructuras, como carreteras y edificios, y de hecho la propia estructura de los asentamientos humanos tendrán que ser modificadas para adaptarse a los cambios en los patrones de precipitación y caudal de los ríos (Sadoff, Claudia & Muller, Mike. 2009).

Los caudales de ríos se forman por los sedimentos que han sido y están siendo transportados por agua que fluye. Estos en general se pueden clasificar en 4 formas básicas: rectos, meandros, trenzados y anastomosados. Los canales sinuosos son a menudo reconocidos como un grado intermedio entre canales meandros y trenzados (Huggett, 2007). Por esto, es importante el tener reconocidos los distintos ríos y para ello no basta con conocer su localización sino además tener mapeadas las características de estos según su canal aluvial, esta caracterización morfológica de los ríos se justifica por los siguientes aspectos (Rosgen, 1994):

1. Predecir el comportamiento de un río de acuerdo a su apariencia.
2. Desarrollar las relaciones específicas de hidráulica y sedimentación para un determinado tipo y estado de morfología del canal.
3. Proporcionar un mecanismo de para extrapolar sitios específicos de colección de información en una determinada corriente a aquellos de similar característica.
4. Proporcionar un marco de comunicación referente, consistente y reproducible, para aquellos que trabajan en sistemas ríos y otras disciplinas relacionadas.

Detectar cuerpos de agua y delimitarlos de sus alrededores con precisión es un aspecto importante para varias aplicaciones científicas. Esta información precisa es vital para áreas como detección de inundaciones, monitoreo y alivio (Smith 1997. Thorley & De Fraipont 1997); inventario de humedales (Beneth 1987. Johnston & Barson 1993. Shaikh, Brady, & Sharma 1997); y evaluación de los recursos hídricos (Manavalan, Sathyanath & Rajegowda 1993. Morse, Zarriello & Kramber 1990).

Uno de los métodos tradicionales para caracterizar la morfología de un río (por ejemplo anchura, sinuosidad, características de inundación, etc.) es a través de trabajo de campo, que es costoso y demanda tiempo (Klemenjak, et.al., 2012). Estos métodos no sólo consumen tiempo, sino que además, son extremadamente difíciles de llevar a cabo (Frazier, J. Page 2000). Factores como inundaciones, mareas y tormentas pueden hacer el lugar inaccesible y peligroso para recolectar información.

Para superar estos inconvenientes y extraer información eficientemente, datos de teledetección han sido usados por muchos científicos con muy buenos resultados (Shrestha & Liping, 2013). Estos datos de teledetección pueden ser obtenidos a partir del análisis de imágenes donde, utilizando algún tipo de procesamiento de imágenes, es posible extraer o identificar un río en cuestión valiéndose además de la visión computacional (encargada de procesar datos visuales con el fin de reconocer objetos) como medio para la extracción de características necesarias para la clasificación del río identificado.

Entre algunos trabajos que buscaron la detección y extracción de características de ríos se tienen: el uso de datos de teledetección y la aplicación del método corte de densidad en única banda (Shrestha & Liping 2013); el método basado en morfología matemática y extracción de características

lineales (Klemenjak, Waske, Valero, & Chanussot 2012); la caracterización del flujo de la corriente y la detección de características usando una transformada *wavelet* discreta (Smith L.C., Turcotte D.L. & Isacks B.L. 1998); entre otros.

El problema enfrentado es la dificultad y el alto costo que supone la realización del trabajo de campo que permita caracterizar la morfología de un río, siendo que al momento, este trabajo se realiza de forma manual por los especialistas hidrólogos. En ese sentido, el presente trabajo propone una nueva técnica computacional para la caracterización automática de la morfología de los ríos, Dimensión Fractal Multi-escala, el cual aprovecha las características fractales de formación de elementos naturales como los ríos.



1.2 Objetivo General

Proponer e implementar una herramienta computacional que permita la clasificación de un río en base a sus características morfológicas. La caracterización se realiza mediante el cálculo de la Dimensión Fractal Multi-escala en la secuencia de píxeles que representan el esqueleto del río, previamente detectada, en imágenes satelitales.

1.3 Objetivos Específicos

- a) Componer un repositorio de ríos identificados, que comprende la selección de imágenes esqueletizadas de ríos, determinando las regiones de interés.
- b) Determinar los patrones característicos mediante el análisis y selección de un conjunto de variables que determinan la forma del caudal de los ríos.
- c) Generar el modelo de clasificación de ríos, mediante la experimentación de algoritmos de aprendizaje de máquina que se adecuen a este tipo de problema y adaptarlo calibrando parámetros (entrenamiento).
- d) Validar el modelo de clasificación mediante técnicas de evaluación de clasificadores así como con la comprobación por parte del especialista hidrólogo.

1.4 Resultados Esperados

- a) Relacionado con Objetivo Específico a:
 1. Algoritmo que procese los ríos identificados (esqueleto) y elimine regiones que no sean de interés.
 2. Contar como mínimo con 40 identificadores (esqueleto) de ríos por cada clase de canal.
- b) Relacionado con Objetivo Específico b:
 1. Algoritmo basado en Dimensión Fractal Multi-Escala que permita extraer características que puedan diferenciar los distintos ríos según su morfología.
 2. Conjunto de características observadas que se usarán para la clasificación de los ríos.
- c) Relacionado con Objetivo Específico c: Algoritmo de clasificación conveniente que permita diferenciar los tipos de ríos, este algoritmo basará su entrenamiento en los datos de los esqueletos seleccionados en el resultado a).

- d) Relacionado con Objetivo Específico d: Reporte de la validación de los resultados de los distintos tipos de ríos clasificados en recto, meandro, trezado, anastomosado y las tasas de acierto para cada uno.

1.5 Herramientas, métodos, metodologías y procedimientos

En la presente sección, se detallarán las herramientas y los métodos y procedimientos que serán empleados durante el proyecto de investigación. Por cada resultado esperado, se especificarán las herramientas, métodos y procedimientos que se utilizarán.



1.5.1 Herramientas

Resultados esperado	Herramientas a usarse
<p>RE1.1. Algoritmo que procese los ríos identificados (esqueleto) y elimine regiones que no sean de interés.</p> <p>RE1.2. Contar como mínimo con 40 identificadores (esqueleto) de ríos por cada clase de canal.</p>	<p>Herramientas de apoyo: Matlab</p>
<p>RE2.1. Algoritmo basado en Dimensión Fractal Multi-Escala que permita extraer características que puedan diferenciar los distintos ríos según su morfología.</p> <p>RE2.2. Conjunto de características observadas que se usarán para la clasificación de los ríos.</p>	<p>Dimensión Fractal Multi-Escala Método para la caracterización morfológica de objetos basado en teoría de fractales.</p> <p>Herramientas de apoyo: Matlab</p>
<p>RE3. Algoritmo de clasificación conveniente que permita diferenciar los tipos de ríos, este algoritmo basará su entrenamiento en los datos de los esqueletos seleccionados en el resultado RE1.</p>	<p>AdaBoost Máquinas de soporte vectorial Herramientas de apoyo: Matlab y Weka</p>
<p>RE4. Reporte de la validación de los resultados de los distintos tipos de ríos clasificados en recto, meandro, trezado, anastomosado y sus tasas de acierto para cada uno</p>	<p>Métodos de evaluación de resultados: matriz de confusión, validación cruzada, curvas ROC, <i>Percentage Split</i>.</p> <p>Herramientas de apoyo: Matlab y Weka</p>

1.5.2 Métodos y procedimientos

En la siguiente sección se detallarán los métodos utilizados y el flujo seguido para la elaboración de la herramienta. En el capítulo 4 se profundizará cada uno de los procedimientos usados.

En la figura 1.1 se observa el esquema general de los procedimientos a seguir.

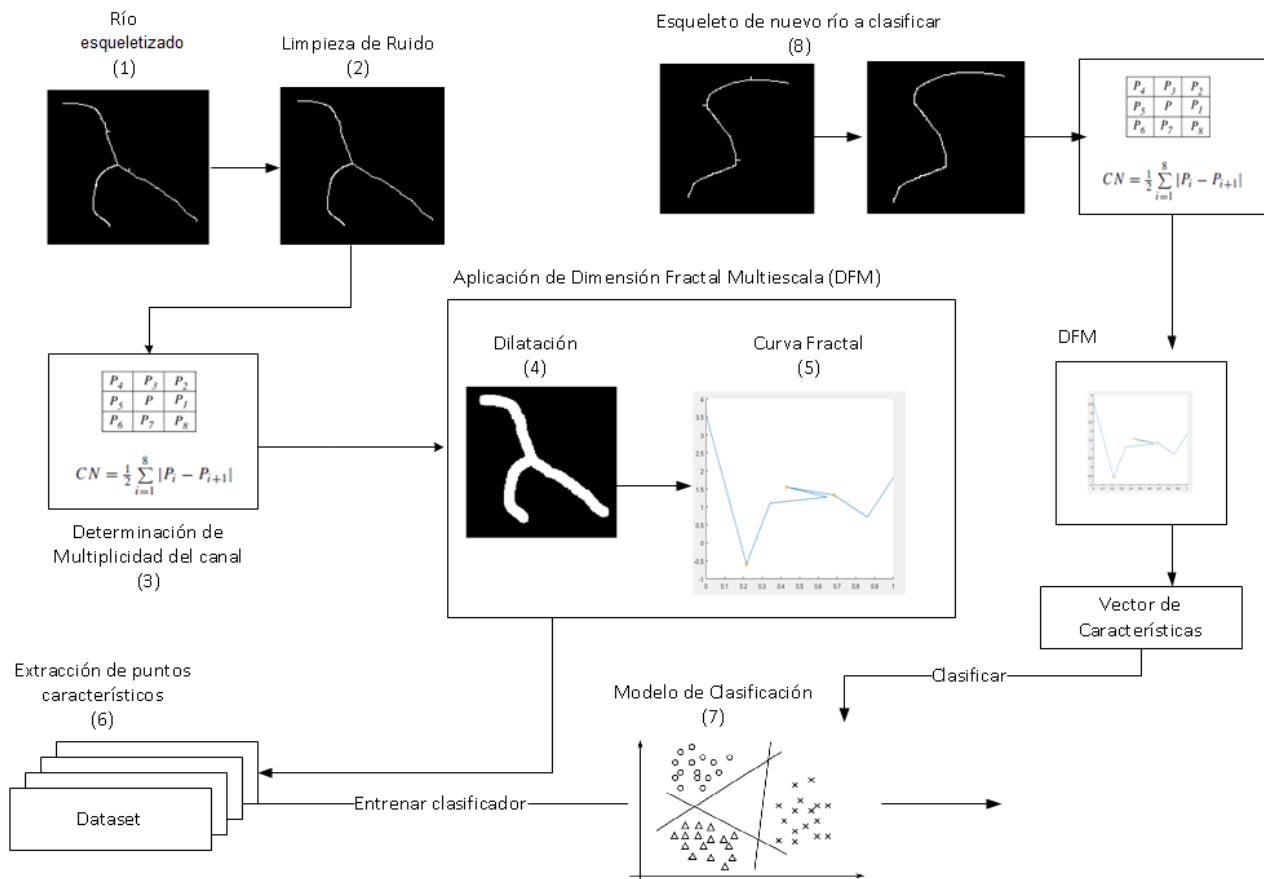


Figura 1.1. Flujo de metodología utilizada.

Elaboración propia

- 1) Se recibirá como entrada a la herramienta la esqueletización de distintos ríos.
- 2) Se realizará una limpieza sobre el esqueleto recibido con el fin de eliminar el ruido que exista para obtener la región de interés.
- 3) Se determinará la multiplicidad del canal del río (si este presenta bifurcaciones) mediante el método de *Crossing Number*.
- 4) Se realizarán dilataciones sucesivas sobre el esqueleto del río conforme al método de Dimensión Fractal Multi-escala (DFM). Las distancias exactas a dilatar son: $[1, \sqrt{2}, \sqrt{3}, 2\sqrt{2}, 2, 3, 4, 5]$.

- 5) Se elaborará la Curva Fractal para el esqueleto dado conforme al método DMF.
- 6) Se extraerán los puntos de interés de la Curva Fractal para obtener el vector de características necesario para la clasificación. Para el trabajo se han considerado los siguientes 3 puntos: La mayor depresión, el mayor pico y el segundo mayor pico.
- 7) Se entrenará un clasificador utilizando los vectores de características obtenidos en la secuencia anterior y finalmente se generará un modelo predictivo.
- 8) El modelo obtenido será evaluado mediante la clasificación de un nuevo esqueleto; para ello, este esqueleto será sometido a la secuencia anterior (pasos del 1 al 6) para obtener su vector de características correspondiente y poder ser clasificado por el modelo.

1.6 Alcance

El presente proyecto, ubicado dentro del área de *Ciencias de la Computación*, se encuentra orientado a la investigación aplicada e implica el desarrollo de una herramienta de software que clasifique, a través del análisis de los patrones de circulación de los caudales de ríos, cuál es el río representado en una determinada imagen satelital previamente trabajada.

Esta herramienta realizará la clasificación en base a 4 canales: rectos, meandros, trezados y anastomosados ya que se cuenta con una mayor información al respecto de sus características.

Debido a la limitación del tiempo para el desarrollo y evaluación del prototipo software, este realizará la clasificación sólo en imágenes digitales que hayan sido previamente procesadas (donde se hayan podido detectar ríos tras un análisis previo).

1.6.1 Limitaciones

Durante el planteamiento del proyecto y la revisión del estado del arte se han identificado ciertas limitaciones que pueden influenciar el proceso de investigación, las cuales se listan a continuación:

- El trabajo toma como imagen de entrada las imágenes previamente esqueletizadas, por lo cual la calidad de los resultados depende de la eficiencia con que se haya realizado este proceso de detección.

1.6.2 Riesgos

A continuación se describen los riesgos y problemas identificados en el proyecto que podrían afectar la continuidad del mismo, además de la valoración del impacto y medidas correctivas que logren mitigar cada uno de estos.

Riesgo identificado	Impacto	Medidas correctivas para mitigar
Tasa de error elevada en la detección previa de ríos que arrastren error para su clasificación.	Alto	Si la tasa de error en la detección de los ríos es alta, se deberá conversar con el asesor y el especialista para determinar qué repositorio de ríos detectados utilizar.



CAPÍTULO 2: MARCO CONCEPTUAL

En esta sección se describirán conceptos relevantes para el entendimiento del problema: cómo caracterizar y clasificar los ríos según su canal aluvial detectados en imágenes satelitales por métodos computacionales; y la solución que se plantea en el proyecto. Es necesario entonces, explicar los distintos canales de ríos a clasificar, los métodos de caracterización morfológica propuestos, aprendizaje de máquina y validación.

2.1 Canales de ríos y su clasificación

Los canales de ríos o canales aluviales se forman por los sedimentos que han sido y están siendo transportados por agua que fluye. Estos, según lo detalla Huggett en su trabajo sobre geomorfología (Huggett, 2007), se pueden clasificar en 4 formas básicas: rectos, meandros, trezados y anastomosados que serán detalladas a continuación y se pueden apreciar en la figura 2.1:

- **Canales rectos:**
Estos no son comunes en el mundo natural. Por lo general se limitan a tramos de valles en forma de V que son rectos debido al control estructural ejercido por fallas naturales. Canales rectos en fondos de los valles planos son casi invariablemente artificiales. Incluso en un canal recto, la vaguada (el rastro de los puntos más profundos a lo largo del canal) por lo general termina de lado a lado, y el perfil de largo por lo general muestra una serie de secciones más profundas y superficiales muy similar a un arroyo serpenteante o una corriente trezada.
- **Canales meandros:**
Representan un recorrido de tipo serpiente a través de una llanura de inundación. La división entre recto y meandro es arbitrariamente definida por una sinuosidad de 1.5, calculada por la división de la longitud del canal por la longitud valle. El patrón de flujo del agua fomenta la erosión y la subvaloración de los bancos en el exterior de curvas y la deposición, y la formación de barras de punto en el interior de las curvas. La posición de meandros cambia, lo que lleva a la alteración del curso a través de puntos de corte y desvío de canal (avulsiones).
Las avulsiones son el cambio repentino en el curso de un río que conduce a una sección del canal abandonado, una sección del nuevo canal, y un segmento de tierra más alta (parte de la llanura de inundación) entre ellos.

Los meandros se favorecen donde los bancos se resisten a la erosión, formando canales profundos y estrechos. Sin embargo, porqué los ríos serpentean no es del todo claro. Se tienen ideas centradas en: la distribución y disipación de la energía dentro de un río; flujo helicoidal; y la interacción de la erosión de las orillas, la carga de sedimentos, y la deposición. Ha surgido un consenso que sugiere que los meandros son causados por las inestabilidades intrínsecas de agua turbulenta contra un banco de canales móvil.

- Multicanales

- Canales Trenzados:

Estos tipos de canales son formas esencialmente deposicionales que se producen donde el flujo de agua se divide en una serie de trenzas separados por islas o barras de sedimento acumulado. Las islas soportan vegetación y duran mucho tiempo, mientras que las barras son más cambiantes en el tiempo. Una vez que las barras se forman en los ríos trezados, son colonizados rápidamente por las plantas, para estabilizar los sedimentos de barras e islas que forman. Sin embargo, contrarrestar el proceso de estabilización es una descarga de corriente muy variable, lo que alienta fases alternas de degradación y agradación (deposición de material por un río o corriente) en el canal y va en contra de la colonización vegetal. Algunos ríos trezados tienen veinte o más canales en un solo lugar.

- Canales anastomosado:

Son similares a los canales trezados, pero los trezados tienen la forma de un único canal cuyo flujo se desvía alrededor de obstáculos en el canal; en cambio, los canales anastomosados son un conjunto de canales interconectados separados por una roca madre o por un aluvión estable. La formación de canales anastomosados se ve favorecida por un régimen agradacional que implica una carga alta de sedimento en suspensión en los sitios donde la expansión lateral se ve limitada.

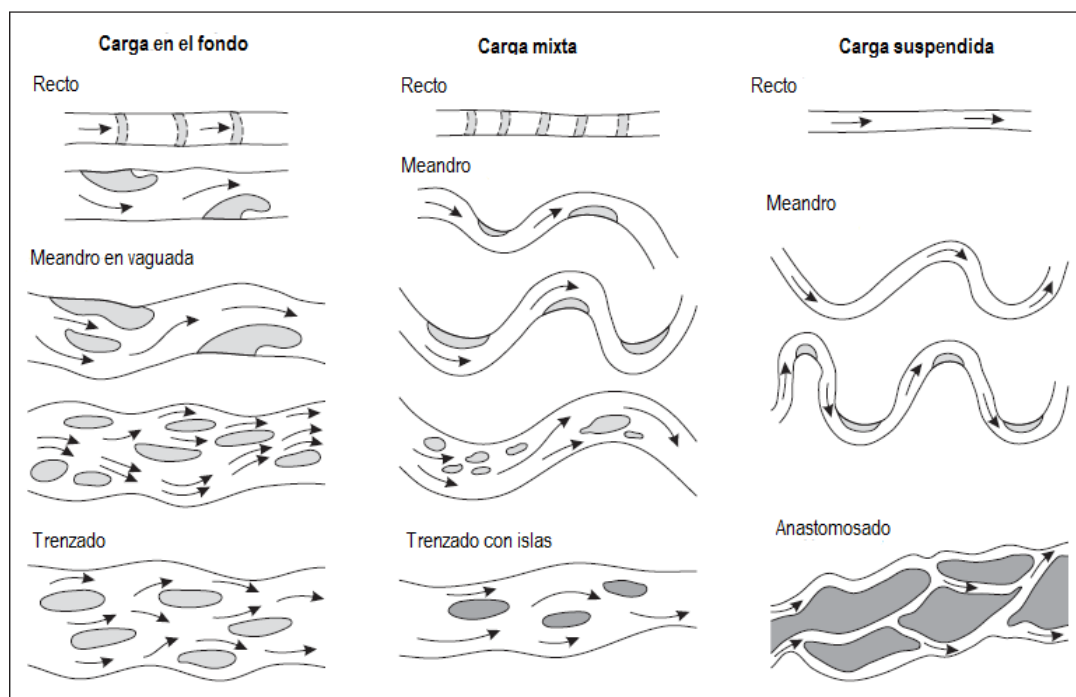


Figura 2.1. Clasificación de patrones de canales de ríos (Adaptado de: Huggett, 2007).

2.2 Descriptores de imágenes

Los descriptores, dentro del campo del análisis de imágenes, son patrones que están conformados por un arreglo o conjunto de características. Adicionalmente, un conjunto de patrones que comparten propiedades en común constituiría una clase. (Gonzales & Woods, 2008).

2.2.1 Descriptores de Bordes

Los descriptores más simples de un borde son: la longitud, el diámetro, la excentricidad y la curvatura. La longitud se define como el número de píxeles a lo largo del borde. El diámetro se define como $Diam(B) = \max_{ij}[D(p_i, p_j)]$, en el cual D es la distancia medida y p_i y p_j son puntos del borde. La línea que une los dos puntos extremos que comprenden el diámetro es conocida como eje mayor, y la línea perpendicular a esta es conocida como eje menor. La proporción entre ambas líneas define al siguiente descriptor, conocido como excentricidad del borde. Finalmente, la curvatura se define como la tasa de cambio de la pendiente del borde (Gonzales & Woods, 2008).

2.2.2 Descriptores de Regiones

Los descriptores más simples de una región son: el área, el perímetro, la compactación y la tasa de circularidad. El área se define como el número de

pixeles en la región. El perímetro se define como la longitud del borde. Tanto el área como el perímetro son usualmente utilizados cuando el tamaño de las regiones de interés no varía (Gonzales & Woods, 2008). La compactación se define como la división del perímetro elevado al cuadrado y el área (p^2/A). Finalmente, la tasa de circularidad se define como la proporción entre el área de un círculo, con el mismo perímetro que la región, y el área de la región.

2.3 Caracterización de regiones en base a la morfología

En el trabajo de (Zhifang, Shulian, Shoudong, & Hui, 2009) se aplica la morfología matemática en la segmentación y caracterización de una imagen de tomografía de coherencia óptica (OCT por sus siglas en inglés) de la piel de un ratón. Aquí se explica rápidamente teoría básica de morfología matemática, indicando que hay dos operaciones morfológicas básicas relacionadas con el procesamiento de imágenes: erosión y dilatación. Se demuestra que realizando un pre-procesamiento a la imagen de OCT de la piel de ratón con la operación de dilatación, en la que el elemento estructurante es en forma de línea, se podría llenar el área oscura que se presenta debido a la distribución estadística de detección fotoeléctrica, y resulta en la segmentación y el aplanamiento de la piel.

2.3.1 Dilatación

Dados dos conjuntos A y B definidos en Z^2 , la dilatación de A dada por B , denotada como $A \oplus B$, se define como:

$$A \oplus B = \{z | (\hat{B})_z \cap A \neq \emptyset\}$$

La dilatación de A dada por B es el conjunto de puntos z , desplazamientos, tal que A y B se superponen por al menos un elemento. En otras palabras, esta operación permite hacer crecer o engrosar objetos en una imagen, la forma específica y el alcance del crecimiento son controlados por un objeto estructural (Gonzales & Woods, 2008). Un objeto o elemento estructural es una imagen binaria o máscara que permite definir estructuras de entornos arbitrarias.

2.3.2 Erosión

Dados dos conjuntos A y B definidos en Z^2 , la erosión de A dada por B , denotada como $A \ominus B$, se define como:

$$A \ominus B = \{z | (B_z) \subseteq A\}$$

La ecuación tiene como significado que la erosión de A dada por B es el conjunto de puntos z tales que B, representado por z, está contenido en A. En otras palabras, esta operación encoge o adelgaza objetos en una imagen, la forma específica y el alcance del encogimiento son controlados por un objeto estructural (Gonzales & Woods, 2008).

2.4 Extracción de minucias del esqueleto de una imagen por *Crossing Number*

En el trabajo de (Feng Zhao & Xiaoou Tang, 2006) se menciona un método de extracción de características analizando a la vecindad de un pixel para determinar qué propiedad tiene respecto a la esqueletización (conjunto de líneas que corresponden al adelgazamiento completo de la región sin perder su forma esencial) a la que pertenece. Este método es el de “*crossing number*”, el cual se define como:

P_4	P_3	P_2
P_5	P	P_1
P_6	P_7	P_8

$$CN = \frac{1}{2} \sum_{i=1}^8 |P_i - P_{i+1}|,$$

Figura 2.2. Crossing Number. (Feng Zhao & Xiaoou Tang, 2006).

Donde P_i es el valor binario del pixel de la vecindad de P que puede indicar un valor de 0 o 1 y $P_1 = P_9$, como se observa en la figura 2.2.

Según el valor que se obtenga en la ecuación, el pixel en cuestión se puede clasificar de la siguiente forma (ver figura 2.3):

Si:

- $CN = 0 \rightarrow P$ es un punto aislado.
- $CN = 1 \rightarrow P$ es un punto terminal.
- $CN = 2 \rightarrow P$ es un punto de conexión.
- $CN = 3 \rightarrow P$ es un punto de bifurcación.
- $CN = 4 \rightarrow P$ es un punto de cruce.

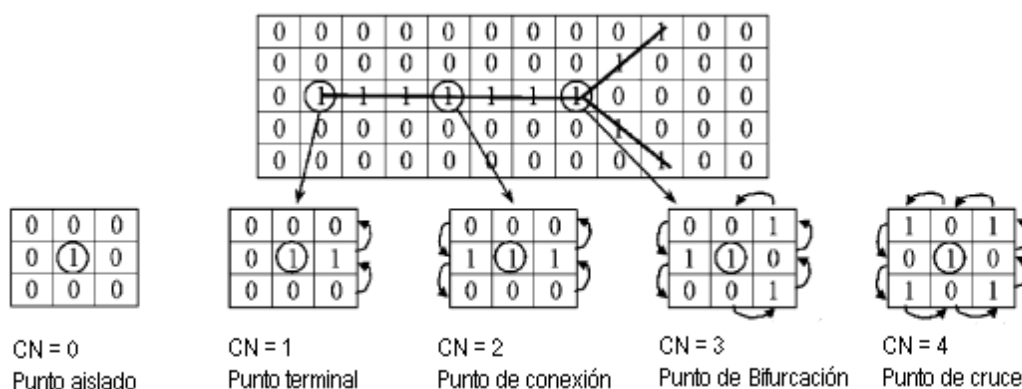


Figura 2.3. Propiedades del pixel según Crossing Number. (Adaptado de Feng Zhao & Xiaou Tang, 2006).

2.5 Caracterización mediante Dimensión Fractal Multi-escala

En el trabajo de Plotze, R. et al (2005) se describe cómo extraer un vector de características analizando los bordes y la esqueletización de las nervaduras de las hojas empleando el método de dimensión fractal multi-escala.

Primero detallan cómo obtener la dimensión fractal a través del método de suma de Minkowski, el cual consiste en una secuencia de expansiones de fronteras (con unidades exactas de distancia), las cuales incrementarán el área de la forma original logrando así tener un área respecto a la distancia que se haya dilatado la forma.

Luego indican que, a diferencia de la dimensión fractal que solo retorna un número, el enfoque multi-escala devuelve una curva, como se observa en la figura 2.4, que puede ser usada para caracterizar mejor la forma. Esta curva es obtenida tomando la derivada de la curva $\log(d)$ por $\log(A)$ donde d representa la distancia dilatada y A representa el área obtenida luego de la dilatación con distancia d .

Finalmente, las curvas obtenidas de la dimensión fractal multi-escala fueron utilizadas como firmas digitales de las distintas formas de hojas que tenían donde los distintos puntos de la curva podían ser considerados como características: sea un punto $P(x,y)$ contenido en la curva, x e y pueden utilizarse como un par de características a emplear para diferenciar clases de hojas. En aquel trabajo se consideraron 3 puntos: P1 correspondiente a la depresión, P2 correspondiente al primer pico y P3 correspondiente al segundo pico, en la figura 2.4 se pueden observar estos 3 puntos característicos para 1 sola muestra y en la figura 2.5 se observa la curva fractal para una muestra de 10 hojas de una misma clase.




Figura 2.4. Curva de dimensión fractal. (Plotze, R et al, 2005).




Figura 2.5. Curvas de dimensión fractal para 10 nervaduras de hoja de la especie *P. maliformis*. (Plotze, R et al, 2005).

2.6 Aprendizaje de Máquina

El aprendizaje de máquina es una rama de la inteligencia artificial, que contiene distintos procedimientos y algoritmos que son capaces de “aprender” a partir de una serie de datos de entrada. En general, el algoritmo de aprendizaje de máquina recibe como conjunto de entrada datos de entrenamiento, que generalmente son resultado de un conjunto de observaciones del tema que se quiere estudiar o predecir. El algoritmo da como resultado un modelo predictivo, al que se le suministran nuevos datos de entrada para así obtener una nueva

predicción sobre el comportamiento o significado de dichos datos. Adicionalmente, existe un conjunto de conceptos asociados a los modelos de aprendizaje (van Leeuwen, 2004):

- Aprendiz: Quién o qué va a realizar el aprendizaje. Los algoritmos de aprendizaje de máquina.
- Dominio: Qué, o sobre qué se quiere aprender. Conceptos, juegos, idiomas, etc.
- Objetivo: Por qué se realiza el aprendizaje. Por ejemplo: extraer una serie de reglas de un conjunto de datos dispersos, ejercer control sobre un sistema, etc.
- Representación: Cómo se van a representar los objetos que quieren ser aprendidos.
- Tecnología algorítmica: El marco de trabajo a utilizar: redes neuronales, árboles de decisión, redes probabilísticas, aprendizaje basado en reglas, máquinas de soporte vectorial, etc.
- Fuente de información: La información que va a ser usada para entrenar. Pueden ser respuestas a preguntas, resultados de determinadas observaciones de un fenómeno dado, etc. Se dice que una fuente de información tiene ruido cuando tiene errores.
- Escenario de entrenamiento: Esta es la descripción del proceso de aprendizaje. Pueden haber escenarios interactivos (on-line) y otros en que los datos de ejemplos se proveen una vez solamente (off-line). También se realiza una distinción entre aprendizaje supervisado y aprendizaje no supervisado. El primero se refiere a la predicción de respuestas que ya se conocen de antemano; mientras que en el segundo, el programa debe determinar ciertas regularidades en los datos para predecir la respuesta por él mismo.
- Conocimiento previo: Lo que se sabe a priori, pueden ser propiedades matemáticas, o conceptos relativos a la naturaleza del problema que se quiera resolver: conceptos biológicos, médicos, etc.
- Criterio de éxito: Criterio que muestre si el aprendizaje fue exitoso o no. Las tasas de éxito se miden a partir de pruebas realizadas al modelo con datos de prueba.
- Performance: Eficiencia en recursos computacionales: tiempo, espacio, y capacidad de procesamiento requerida para determinada tarea.

2.6.1 Aprendizaje Supervisado

Se denomina aprendizaje supervisado debido a que este se basa sobre la experiencia. Está compuesto por un conjunto de algoritmos y técnicas que son capaces de aprender a partir de datos de entrenamiento. Estos algoritmos deberán ser capaces de generalizar su respuesta para cualquier dato de entrada que no exista en los datos de entrenamiento (Marsland, 2009).

A continuación serán descritos los algoritmos que son usados en el presente trabajo:

2.6.1.1 AdaBoost

Se conoce con el nombre de *Boosting* a una técnica de aprendizaje de máquina que permite, a partir de la combinación de varias reglas de predicción poco exactas, obtener una regla de predicción mucho más exacta. La técnica procede de la siguiente forma: Se provee al *booster* de un conjunto de datos de entrenamiento etiquetados correctamente $(x_1, y_1) \dots (x_n, y_n)$, en donde “ y_i ” es la etiqueta asociada a una instancia “ x_i ”. En cada iteración, $t = 1, \dots, T$, el booster encuentra una distribución de probabilidad “ D_t ” sobre el conjunto de datos y solicita una hipótesis débil (a uno de los clasificadores débiles) “ h_t ” con un error “ ϵ_t ” respecto de “ D_t ”. De esta forma, la distribución “ D_t ” especifica la relativa importancia para cada uno de los ejemplos de prueba. Luego de T rondas, el booster debe combinar las hipótesis débiles en una sola regla de predicción (Freund & Schapire, 1997).

Una variante de esta técnica es conocida como AdaBoost, forma corta de *Adaptive Boosting* y fue propuesta por Freund y Schapire en 1996. Esta técnica usa el mismo conjunto de datos de entrenamiento varias veces por lo cual no es necesario que sea muy grande (Bishop, 2006). La principal diferencia entre *Boosting* y *AdaBoost* es que esta última no necesita conocer a priori la precisión de las hipótesis débiles. En su lugar, la precisión se adapta y genera una hipótesis de mayoría ponderada en la cual el peso de cada hipótesis débil es una función de su precisión (Freund & Schapire, 1997).

2.6.1.2 SVM

Support Vector Machine (SVM) es uno de los algoritmos de aprendizaje de máquina más populares en la actualidad. Fue introducido por primera vez

por Vapnik, V. en 1992, y ha sido ampliamente usado desde la fecha, debido a que, en comparación con otros algoritmos de aprendizaje, ofrece una precisión superior en problemas de clasificación para conjuntos de datos de razonable tamaño (Marsland, 2009).

Para el problema de clasificación dado por dos clases, se tiene el siguiente modelo lineal:

$$y(x) = w^T \phi(x) + b$$

En el cual $\phi(x)$ representa una transformación fija del espacio de características y b representa un parámetro de parcialidad. El conjunto de datos de entrenamiento esta formado por N vectores de entrada x_1, \dots, x_N con sus correspondientes valores objetivo, o etiquetas t_1, \dots, t_N en el cual $t_N \in \{-1, 1\}$, y los nuevos puntos son clasificados según el signo de $y(x)$. En SVM, este problema es atacado a partir del concepto de margen, el cual es definido como la distancia mínima entre el límite de decisión y cualquiera de los puntos clasificados (Bishop, 2006). Los puntos en cada clase que fueron clasificados de manera más cerca al límite de decisión son conocidos como *support vectors*. Por lo tanto, el objetivo es conseguir un margen lo más ancho posible y; además, tener en cuenta que los *support vectors* tienen un rol principal en el método, lo cual deja entre ver una importante característica de este algoritmo, y es que luego de haberse realizado el entrenamiento, todos los datos, excepto los *support vectors*, pueden ser eliminados ya que no serán necesarios para la clasificación (Marsland, 2009).

Como se ha descrito, las máquinas de soporte vectorial han sido diseñadas originalmente para realizar clasificaciones binarias (determinar si una entidad pertenece a una de dos clases). Sin embargo, es posible trabajar con más de dos clases aplicando una de las dos estrategias que se mencionan a continuación:

- Uno contra uno – Esta estrategia consiste en evaluar todas las posibles combinaciones de clases y aplicar el clasificador a cada una de ellas.
- Uno contra el resto – En este caso, por cada clase se realiza el entrenamiento, poniendo dicha clase contra el resto

Debido a que la segunda alternativa es relativamente más simple y genera un menor costo computacional debido a la cantidad de veces que es necesario hacer el entrenamiento, generalmente se opta por utilizar esta alternativa.

Para este enfoque, el procedimiento consiste en: (i) separar los datos en datos de entrenamiento y datos de prueba; (ii) seleccionar los parámetros de entrenamiento (método de entrenamiento multiclase, valor del parámetro de penalidad C , núcleo); (iii) entrenar, analizar y evaluar el rendimiento del proceso en la clasificación (Chapelle, 1998).

2.6.1.2.1 Selección del parámetro de penalidad C

Las máquinas de soporte vectorial hacen uso de un valor de penalidad C . El efecto de la selección de este parámetro puede verse en la Figura 2.6. En la imagen de la izquierda, se ha seleccionado un valor de C grande, lo cual hace que el margen de separación sea muy pequeño. En la imagen de la derecha, se seleccionó un valor de C menor lo cual permite ignorar algunos de los puntos que están cerca de la frontera y ampliar el margen. La frontera de decisión entre las muestras negativas (círculos rojos) y positivas (cruces azules) se muestra con la línea gruesa. Las líneas delgadas representan el margen (Ben-Hur & Weston, 2010). Es importante resaltar que ampliar este margen de manera óptima es el objetivo de las máquinas de soporte vectorial.




Figura 2.6. Efecto del parámetro de penalidad C (Ben-Hur & Weston, 2010)

2.6.1.2.2 Elección del *Kernel*

Las máquinas de soporte vectorial pertenecen a la categoría de métodos de núcleo, esto significa que el algoritmo manipula los datos solamente mediante productos punto. Estos pueden ser reemplazados por funciones de núcleo, que computan estos productos punto en espacios de características de mayor dimensión (Ben-Hur & Weston, 2010).

La elección del núcleo también tiene un gran impacto en el funcionamiento del algoritmo y va a depender de las características de los datos de cada problema: la cantidad de datos y su dimensionalidad, etc. Los núcleos más usados en la literatura son (Chapelle, 1998):

- Lineal
- Polinomial
- Gaussiano o Función de Base Radial (RBF)
- Red Neuronal

Los parámetros de cada núcleo también tienen efecto en los resultados que se obtengan. Así, por ejemplo, se tiene el grado del núcleo polinomial. El núcleo polinomial de menor grado es el núcleo lineal, pero este puede no ser suficiente si existe una correspondencia no lineal entre algunas de las características.

2.7 Métodos de evaluación de resultados

Una vez que se ha aplicado el algoritmo de clasificación, es necesario validar sus resultados para conocer la eficacia del mismo. Existen varios métodos para alcanzar este fin, entre ellos validación cruzada, matrices de confusión, curvas ROC y *percentage split* los cuales se describen a continuación.

2.7.1 Validación cruzada

Esta técnica de validación consiste en dividir el conjunto de datos y realizar entrenamientos sucesivos donde las partes son empleadas como datos de entrenamiento y de prueba alternativamente.

2.7.1.1 Validación cruzada de k hojas

En este tipo de validación el conjunto de datos D es dividido en k subconjuntos mutuamente exclusivos (las hojas) de aproximadamente el

mismo tamaño. Este conjunto de datos es entrenado y probado k veces, en cada iteración $t \in \{1, 2, \dots, k\}$, el entrenamiento se realiza sobre $D \setminus D_t$ y las pruebas se realizan sobre D_t . La estimación de acierto está dada entonces por el número total de instancias correctamente clasificadas, entre el tamaño del conjunto de datos. Cuando $k = n$, donde n es la cantidad de instancias en el conjunto de datos, la validación se conoce como *leave-one-out*. (Kohavi, 1995).

2.7.2 Percentage Split

En este tipo de validación se divide aleatoriamente los datos de entrenamiento en dos partes definidas por un porcentaje: la primera, con la que se desarrollará el modelo; y la segunda, con la que se medirá su desempeño. Con este enfoque de muestra dividida, el rendimiento del modelo se determina en datos similares pero independientes (Picard RR, Berk KN, 1990).

2.7.3 Matriz de confusión

La matriz de confusión es una tabla que muestra una relación de la cantidad de instancias clasificadas por cada clase. Si se considera un problema de clasificación con tres clases C_1 , C_2 y C_3 , la matriz de confusión sería la que se ilustra en la Figura 2.7. Los valores en la diagonal representan el número de instancias correctamente clasificadas por cada clase, mientras que el resto de los valores representan instancias clasificadas erróneamente. Por ejemplo, el valor C_{23} indica la cantidad de instancias que eran de tipo C_2 pero que fueron clasificadas erróneamente como de tipo C_3 (Roiger & Geatz, 2003).

	C_1	C_2	C_3
C_1	C_{11}	C_{12}	C_{13}
C_2	C_{21}	C_{22}	C_{23}
C_3	C_{31}	C_{32}	C_{33}

Figura 2.7. Matriz de confusión (Roiger & Geatz, 2003).

2.7.4 Curvas ROC

Las curvas ROC (Receiver Operating Characteristics) son una herramienta usada para la evaluación del rendimiento de los clasificadores cuyo método de construcción se ilustrará mediante el ejemplo que se expone a continuación (Fawcett, 2005).

Se considera un problema de clasificación de dos clases p y n . Se asume que existe un modelo de clasificación que mapea cada instancia l a una de estas dos clases. Se denominan *verdaderos positivos* aquellas instancias que fueron clasificadas correctamente como p , y *falsos positivos* las que fueron clasificadas erróneamente como p . De la misma manera, llamaremos *verdaderos negativos* aquellas instancias que fueron clasificadas correctamente como n , y *falsos negativos* las que fueron clasificadas erróneamente como n . Entonces se pueden definir las siguientes métricas (Fawcett, 2005):

$$\text{tasa vp} = \frac{\text{verdaderos positivos}}{\text{total de positivos (p)}}$$

$$\text{tasa fp} = \frac{\text{falsos negativos}}{\text{total de negativos (n)}}$$

En una curva ROC, el eje de las abscisas corresponde con la *tasa fp* y el eje de las ordenadas con *tasa vp*, de modo que se representa la relación costo-beneficio. Una forma de valorar el resultado de la clasificación, es calculando el área bajo la curva ROC, llamada AUC, la cual se encuentra entre 0.5 y 1.0. La Figura 2.8 muestra las curvas ROC para los clasificadores A y B. El área bajo la curva de B es mayor que la de A y se concluye que el clasificador B tiene un mejor rendimiento promedio.




Figura 2.8. Curvas ROC para los clasificadores A y B (Fawcett, 2005).

2.8 Conclusión

Los conceptos detallados en esta sección sirven para brindar un mayor grado de entendimiento a la problemática propuesta en el presente proyecto (cómo realizar la caracterización de los ríos, según su canal aluvial, detectados en imágenes satelitales por métodos computacionales) y cómo afrontarlo. Asimismo, los conceptos mencionados serán reutilizados como base para poder desarrollar una herramienta que facilite la clasificación de ríos en imágenes donde se hayan identificado los mismos.



CAPÍTULO 3: ESTADO DEL ARTE

En esta sección se brinda un resumen de los principales trabajos existentes relacionados al procesamiento de imágenes y a la detección de ríos en imágenes. Se han considerado distintos trabajos que contemplan técnicas como segmentación, detección, clasificación, entre otras. Esta sección estará compuesta por los avances respecto a la caracterización de regiones en imágenes a color y avances respecto a caracterización de imágenes según su morfología y viendo cómo estos se utilizan en problemas afines.

3.1 Datos de teledetección y método SBDS

Según el trabajo de Shrestha & Liping (2013), los datos de teledetección proveen medios funcionales para delinear fronteras y áreas de cuerpos de agua (ríos, lagos, etc) sobre una gran área en un punto específico del tiempo. Usualmente para capturar cuerpos de agua que se mueven rápidamente como ríos, arroyos u otros.

Uno de los aspectos importantes en usar imágenes satelitales como Landsat no es sólo entender cómo usar la imagen, sino determinar qué banda espectral y qué método de clasificación provee mejores resultados. Parece ser que la mejor banda en Landsat TM para mapear cuerpos de agua es la banda 5 (infrarrojo medio) con el uso del método “corte de densidad en única banda” (SBDS por sus siglas en inglés).

El método SBDS mejora características de una imagen combinándose el número digital (DN por sus siglas en inglés) de diferentes valores del pixel de un rango específico o intervalo a un solo valor. Este es un método simple y eficiente de separar características, especialmente en imágenes de una sola banda. Este método combina todos los rangos especificados de los DN a un único grupo y los asigna/separa de otro grupo único (usualmente asignando diferentes colores).

3.2 Método basado en morfología matemática y extracción de características lineales

El trabajo de Klemenjak, Waske, Valero, & Chanussot (2012) detalla lo siguiente: el análisis morfológico de imágenes es una poderosa y multifuncional herramienta en procesamiento de imágenes. Ajustes de tamaño y forma del elemento estructurante a las propiedades geométricas de los objetos de la imagen deben ser realizadas para obtener resultados adecuados. Algunos

elementos estructurantes comunes son las áreas simétricas (diamantes, discos o cuadrados) o segmentos de línea recta, que pueden ser rotados para probar la adecuación en varias direcciones. El problema de tal enfoque morfológico es la falta de flexibilidad para poder detectar estructuras lineales y curvas en todas las direcciones posibles. Consecuentemente, métodos que siguen este enfoque usualmente son inadecuados para el contexto de detección de ríos puesto que los resultados que se obtengan son limitados para describir el curso de un río adecuadamente.

3.2.1 Perfiles morfológicos usando apertura y cierre de rutas

Para abordar esta limitación anterior, la apertura y cierre de rutas han sido propuestos en los últimos años como un filtro flexible morfológico más. Estos operadores mantienen las estructuras orientadas lineales más oscuras que sus alrededores inmediatos. Estudiando la escala de nivel de gris, estos filtros asignan a cada pixel el mayor (respectivamente el menor) nivel de gris en un camino donde la longitud requerida L_{min} se ha formado, ver figura 3.1. Entonces este parámetro puede ser interpretado como el tamaño del elemento estructurante para estos filtros morfológicos. Referente a la forma del elemento estructurante, estos filtros proponen el uso de grafos de adyacencia para determinar la conectividad de los pixeles vecinos. Estos filtros usan un set de 4 distintos grafos de adyacencia correspondientes a las 4 orientaciones clásicas como 4 elementos estructurantes: un grafo para líneas horizontales, uno que produzca líneas verticales aproximadas, y 2 que creen líneas diagonales aproximadas. Respecto a estas 4 adyacencias, apertura (y cierre) de ruta es equivalente al *supremum* (respectivamente el *infimum*) de todas las aperturas (respectivamente cierres), usando estas 4 adyacencias como 4 elementos estructurantes.

El cierre de ruta detecta rutas que son más oscuras que sus alrededores y tienen un largo igual o mayor al L_{min} . Por tanto, el largo de la ruta (L_{min}) afecta grandemente el resultado obtenido por cierre de ruta.

Para usar la información que provee distintos valores de L_{min} , se propone la construcción de perfiles morfológicos (MPs por sus siglas en inglés), usando aperturas y cierres de rutas.

Tomando como ejemplo una imagen $I(x,y)$ y como mayor valor de L_{min} " K ", el perfil morfológico para cada pixel " p " se computa como:

$$MP(i) = \begin{cases} \text{Opening}(I(p))_{Lmin} = -i; & i = -k, -k + 1, \dots, -1; \\ I(p); & i = 0; \\ \text{Closing}(I(p))_{Lmin} = i; & i = 1, 2, \dots, k \end{cases}$$

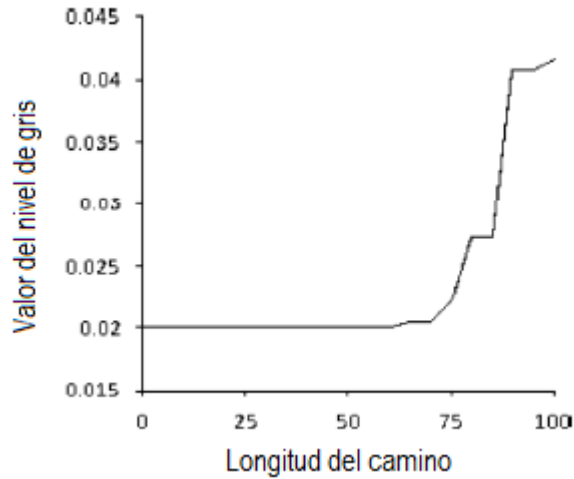


Figura 3.1. Perfil morfológico de un pixel típico de río. (Adaptado de: Klemenjak, Waske, Valero, & Chanussot, 2012).

3.2.2 Extracción de características lineales usando Thresholds

Un cierre de ruta con un $Lmin$ grande es computado para obtener las estructuras más largas y oscuras en la imagen, que son los pixeles con bajos valores de gris. Estos pixeles son seleccionados por un primer Threshold (T1) manual y usado como máscara para el cómputo del nivel de gris mediano (MGL por sus siglas en inglés), el cual es el valor medio de los pixeles contenidos en la aplicación de la máscara mencionada en la imagen de entrada. El rango del MGL depende del rango de nivel de gris de la imagen estudiada. El perfil morfológico generado de acuerdo con la fórmula del punto 3.3.1 será comparado al MGL y una nueva imagen L' será definida como:

$$L'(p) = \min\{Lmin | MP(i) > MGL\}$$

El río ahora puede ser seleccionado escogiendo los pixeles con un valor $L'(p)$ mayor que un segundo threshold (T2) manual.

3.3 Caracterización del flujo de la corriente y la detección de características usando una transformada wavelet discreta

En el trabajo de Smith L.C., Turcotte D.L. & Isacks B.L. (1998) se realiza la detección de las características del flujo de la corriente de los ríos con un escalograma de wavelet utilizando 2 ríos típicos que muestran fluctuaciones de descarga dependientes en el tiempo. Finalmente se realiza un análisis espectral de wavelet para un conjunto de registros de descarga diaria para 91 ríos.

Las funciones base de wavelet no son fijas, ya sea en longitud o forma. En cambio, ondas sucesivas son reajustadas con un factor de escala "a". Cada wavelet se hace pasar sobre la señal s(t) con una translación en el tiempo "b". En una forma continua, la transformada de wavelet (WT) es expresada por:

$$WT(b, a) = \frac{1}{\sqrt{a}} \int g\left(\frac{t-b}{a}\right) s(t) dt$$

Donde g(t) es la llamada "wavelet madre" en b=0, a=1. Todas las subsecuentes wavelets son versiones re-escaladas de la wavelet madre. El área de cada wavelet debe sumar cero, y la amplitud del wavelet debe disminuir conforme la escala a aumente.

La integral de cada vector magnitud respecto al tiempo para obtener el total de la energía en cada wavelet con escala a permite la construcción de curvas espectrales que reflejen la distribución de eventos de escala de tiempos contenidos en la señal.

3.4 Métodos de clasificación de ríos

El trabajo de Rosgen (1994) desarrolla una clasificación de canales fluviales considerando 4 niveles de detalle:

1. Nivel I

- Descripción de Inventario: Caracterización Morfológica Amplia.
- Información Requerida: Forma del relieve, litología, suelos, clima, historia deposicional, relieve de la cuenca, morfología del valle, morfología del perfil del río y patrón general del río.
- Objetivos: Para describir características fluviales generalizadas utilizando la teledetección y los inventarios de la geología, la evolución del relieve, la morfología del valle, la historia deposicional y laderas de los ríos asociados, relieve y patrones utilizados para las categorías

generales de los principales tipos de flujo y las interpretaciones asociadas existentes.

2. Nivel II

- Descripción del Inventario: Descripción Morfológica (tipos de corriente).
- Información Requerida: Patrones del canal, relación de afianzamiento, relación ancho/profundidad, sinuosidad, material del canal y la pendiente.
- Objetivos: Este nivel delinea tipos de corrientes homogéneas que describen pendientes específicas, materiales del canal, dimensiones y patrones de mediciones de “alcance de referencia”. Proporciona un mayor nivel de detalle de interpretación y extrapolación que el Nivel I.

3. Nivel III

- Descripción del Inventario: “Estado” o condición de la corriente.
- Información Requerida: Vegetación de la ribera, patrones de sedimentación, patrones de meandros, características de confinamiento, índices de hábitat de los peces, régimen de la corriente, categoría del tamaño del río y banco de erosionabilidad.
- Objetivos: El “estado” de las corrientes describe condiciones existentes que influyen en la respuesta de los canales ante cambios impuestos y proveen información específica para metodologías de predicción (como cálculo del banco de erosionabilidad del canal, etc.). Prevé descripciones muy detalladas y predicciones/interpretaciones asociadas.

4. Nivel IV

- Descripción del Inventario: Verificación.
- Información Requerida: Implica mediciones/observaciones directas del transporte de sedimentos, las tasas de erosión, procesos de agradación y degradación, geometría hidráulica, data biológica como biomasa de los peces, insectos acuáticos, evaluación de vegetación ribereña, etc.
- Objetivos: Proporciona información específica sobre los procesos de alcance de los canales. Utilizado para evaluar metodologías de predicción; para brindar información biológica, de sedimentos e hidráulica relacionada a un tipo específico de corriente; y para evaluar la efectividad de las evaluaciones de impacto y mitigación de las actividades por tipo de corriente.

3.5 Conclusiones sobre el estado del arte

La revisión de los diversos trabajos referentes a la resolución de problemas afines, permite conocer distintos métodos y enfoques que se podrían reutilizar en este proyecto.

Por tal motivo se vio conveniente, como se mencionó anteriormente, el detallar en la revisión del estado del arte los avances respecto a la caracterización de regiones mostrando distintos métodos y enfoques existentes al respecto y cómo estos pueden ser utilizados.



CAPÍTULO 4: EXTRACCIÓN DE CARACTERÍSTICAS DEL ESQUELETO DE UN RÍO

El presente capítulo se divide en dos secciones. En primer lugar, se detallará el método de extracción de una característica que ayude a determinar que un río presente un único canal o esté conformado por 2 o más. Por otro lado, se detallará el método de extracción de un vector de características que ayude a diferenciar las clases de ríos empleando el enfoque de dimensión fractal multi-escala de Minkowski. En el Anexo 1 se detalla el código empleado para la elaboración de los métodos que se explicarán.

Este proyecto toma como entrada imágenes satelitales de ríos que hayan pasado por un proceso previo de esqueletización, el cual consiste en reducir el río de la imagen a un conjunto de líneas que corresponden al adelgazamiento completo de la región sin perder su forma esencial, en la figura 4.1 se puede apreciar la imagen original de un río (lado izquierdo) y su posterior esqueletización (lado derecho).




Figura 4.1. Imagen de un río meandro (izquierda) y su Esqueletización (derecha).

Elaboración propia

4.1 Limpieza de ruido

Para garantizar una correcta caracterización del esqueleto del río, es necesario realizar una limpieza previa del mismo con el fin de eliminar ciertas zonas que puedan dificultar una correcta extracción de características.

Para ello, para un número de veces determinado, se establecerá a 0 los píxeles que posean sólo 1 píxel de 8 conectado en su vecindad (otra forma de evaluarlo es si su valor de *Crossing Number* es igual a 1, lo que correspondería a un píxel terminal). Con esta operación se eliminarán las bifurcaciones presentadas por error en la esqueletización, como se puede observar en la figura 4.2.



Figura 4.2. Limpieza previa a la caracterización del esqueleto del río.

Elaboración propia

4.2 Determinación de multiplicidad de canal

A continuación se presenta a detalle el método de extracción de una característica que ayude a determinar la multiplicidad de canal presente en un río considerando el concepto de “crossing number” (de aquí en adelante CN).

Considerando una esqueletización previa del río a clasificar, se evaluará el CN de cada píxel que componga o forme parte de dicho esqueleto, es decir únicamente los píxeles activos. El valor CN obtenido por cada píxel evaluado se almacenará en una nueva matriz (de las mismas dimensiones que la imagen que almacene el esqueleto) en la misma posición del píxel evaluado. A continuación se puede apreciar el bosquejo de un río (figura 4.3), su constitución a nivel de píxeles (figura 4.4) y finalmente la aplicación del *crossing number* por cada píxel que lo representa (figura 4.5).



Figura 4.3. Bosquejo del esqueleto de un río con una bifurcación presente.

Elaboración propia

	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73
64	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
65	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
66	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
67	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0
68	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
69	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
70	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0
71	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
72	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
73	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0
74	0	0	0	0	0	1	1	1	1	1	1	0	0	0	0	0
75	0	0	0	1	1	1	0	0	0	0	0	1	0	0	0	0
76	1	1	1	1	0	0	0	0	0	0	0	0	1	0	0	0
77	1	0	0	0	0	0	0	0	0	0	0	0	0	1	1	0
78	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1
79	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
81	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
82	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
83	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
84	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Figura 4.4. Constitución de píxeles de la Figura 4.3. La celda marcada indica la bifurcación.

Elaboración propia

	58	59	60	61	62	63	64	65	66	67	68	69	70	71	72	73
64	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0
65	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0
66	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0
67	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0	0
68	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0
69	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0
70	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0	0
71	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0
72	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0
73	0	0	0	0	0	0	0	0	2	0	0	0	0	0	0	0
74	0	0	0	0	0	2	2	2	3	2	2	0	0	0	0	0
75	0	0	0	2	2	2	0	0	0	0	2	0	0	0	0	0
76	2	2	2	2	0	0	0	0	0	0	0	2	0	0	0	0
77	2	0	0	0	0	0	0	0	0	0	0	0	2	2	0	0
78	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2
79	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
80	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
81	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
82	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
83	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
84	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Figura 4.5. Nueva matriz que contiene los valores CN por cada pixel. La celda marcada indica la bifurcación señalada en Figura 4.3 y 4.4, presenta un valor CN = 3.
Elaboración propia

Como característica a emplear se utilizará la suma de la cantidad de pixeles del esqueleto cuyo valor de CN sea 3 o 4 para determinar si posee o no bifurcaciones. A pesar que el valor que indica que existe una bifurcación es el CN = 3, también se considera CN = 4 dado que indica un cruce y este puede ser considerado como una bifurcación.

4.3 Extracción de características empleando método de dimensión fractal multi-escala

A continuación, se detalla la metodología empleada para la extracción de un vector de características empleando el concepto de dimensión fractal multi-escala considerando la esqueletización previa del río a evaluar.

Primero, se define un vector que contenga las distancias con las que se pueda generar una secuencia de expansiones de fronteras que permitan, como se mencionó en el capítulo anterior, obtener relaciones entre área respecto a

distancia dilatada. Las distancias utilizadas se definen en el siguiente vector:
[1, $\sqrt{2}$, $\sqrt{3}$, $2\sqrt{2}$, 2, 3, 4, 5].

Luego, por cada distancia contenida en dicho vector se dilatará la imagen utilizando dicha distancia. Para hacer esto, el enfoque común de dilatación (mencionado en el capítulo 2) queda descartado dado que hace uso de un elemento estructurante donde no se involucra la distancia. Para hacer frente a este problema se optó por hacer una variante de la dilatación empleando la transformada de la distancia (ver figura 4.7) donde por cada pixel se calcula la distancia a los pixeles que lo rodean y se aplica un threshold para dicha distancia. Matlab permite ejecutar esta operación mediante el comando `bwdist(bw) <= d`; donde `bw` es la imagen binaria y `d` la distancia de dilatación deseada.

En la figura 4.6 se puede observar la ejecución de dicha técnica para una dilatación que requiera una distancia de valor 7, tomando como base la figura 4.3.




Figura 4.6. Dilatación de Figura 4.3 empleando una distancia = 7.
Elaboración propia

	10	11	12	13	14	15	16	17	18	19	20	21	22	23
1	14.7648	14.3178	13.9284	13.6015	13.3417	13.1529	13.0384	13	13	13	13	13	13	13
2	13.8924	13.4164	13	12.6491	12.3693	12.1655	12.0416	12	12	12	12	12	12	12
3	13.0384	12.5300	12.0830	11.7047	11.4018	11.1803	11.0454	11	11	11	11	11	11	11
4	12.2066	11.6619	11.1803	10.7703	10.4403	10.1980	10.0499	10	10	10	10	10	10	10
5	11.4018	10.8167	10.2956	9.8489	9.4868	9.2195	9.0554	9	9	9	9	9	9	9
6	10.6301	10	9.4340	8.9443	8.5440	8.2462	8.0623	8	8	8	8	8	8	8
7	9.8995	9.2195	8.6023	8.0623	7.6158	7.2801	7.0711	7	7	7	7	7	7	7
8	9.2195	8.4853	7.8102	7.2111	6.7082	6.3246	6.0828	6	6	6	6	6	6	6
9	8.6023	7.8102	7.0711	6.4031	5.8310	5.3852	5.0990	5	5	5	5	5	5	5
10	8.0623	7.2111	6.4031	5.6569	5	4.4721	4.1231	4	4	4	4	4	4	4
11	7.6158	6.7082	5.8310	5	4.2426	3.6056	3.1623	3	3	3	3	3	3	3
12	7.2801	6.3246	5.3852	4.4721	3.6056	2.8284	2.2361	2	2	2	2	2	2	2
13	7.0711	6.0828	5.0990	4.1231	3.1623	2.2361	1.4142	1	1	1	1	1	1	1
14	7	6	5	4	3	2	1	0	0	0	0	0	0	0
15	7.0711	6.0828	5.0990	4.1231	3.1623	2.2361	1.4142	1	1	1	1	1	1	1
16	7.2801	6.3246	5.3852	4.4721	3.6056	2.8284	2.2361	2	2	2	2	2	2	2
17	7.6158	6.7082	5.8310	5	4.2426	3.6056	3.1623	3	3	3	3	3	3	3
18	8.0623	7.2111	6.4031	5.6569	5	4.4721	4.1231	4	4	4	4	4	4	4
19	8.6023	7.8102	7.0711	6.4031	5.8310	5.3852	5.0990	5	5	5	5	5	5	5
20	9.2195	8.4853	7.8102	7.2111	6.7082	6.3246	6.0828	6	6	6	6	6	6	6
21	9.8995	9.2195	8.6023	8.0623	7.6158	7.2801	7.0711	7	7	7	7	7	7	7

Figura 4.7. Matriz que representa a la Figura 4.2 y la distancia entre cada pixel activo con el resto (un pixel activo posee el valor 0).
Elaboración propia

Una vez efectuada la dilatación se procede a calcular el área que genera dicha dilatación.

Obtenidas todas las áreas generadas tras dilatar la imagen original n veces (n=tamaño del vector de distancias definido al inicio), se genera una curva, que se aprecia en la figura 4.8, donde la abscisa es el logaritmo de la distancia, y la ordenada el valor del logaritmo del área obtenida tras dilatar la imagen original dicha distancia.




Figura 4.8. Curva que representa en el eje $x = \log(d)$ y en el eje $y = \log(A(d))$.
Elaboración propia

A continuación, esta curva es aproximada a una función, la cual será derivada y generará la curva de dimensión fractal. Matlab permite aproximar esta curva a una función mediante el comando `spline(x,y)` donde x e y son las coordenadas de la curva. La figura 4.9 muestra la curva de dimensión fractal para una muestra de 40 ríos meandros, 40 rectos y 40 multicanal.

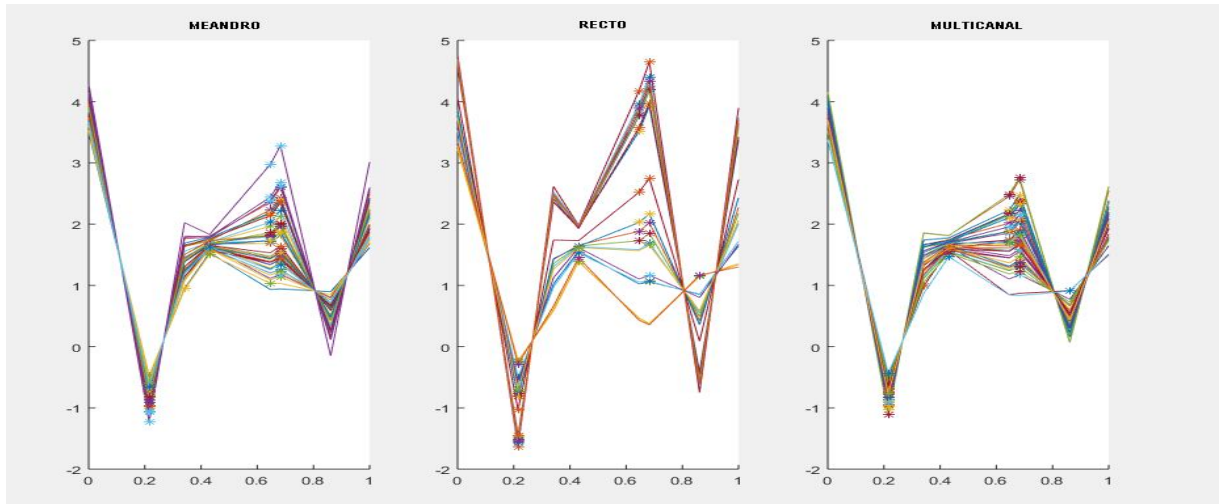


Figura 4.9. Curva que representa la dimensión fractal para una muestra de 40 esqueletos de ríos meandros, 40 esqueletos de ríos rectos y 40 esqueletos de ríos multicanal, en el eje $x = N \log(d)$ es la normalización de $\log(d)$ y en el eje y es la forma derivada de $\log(A)$ por $\log(d)$.

Elaboración propia

Una vez obtenidas estas curvas, se calculan 3 puntos de interés:

- P1 = La mayor depresión.
- P2 = El mayor pico.
- P3 = El segundo mayor pico.

De estos 3 puntos se obtiene un vector de 6 características distintas que son las coordenadas correspondientes a dichos puntos.

Sea N = Número de bifurcaciones (hallado en el punto 4.2), $P1=(x1,y1)$, $P2=(x2,y2)$ y $P3=(x3,y3)$; el vector de características obtenido estaría definido por:

$$\text{FeatureVector} = [N; x1; x2; x3; y1; y2; y3]$$

CAPÍTULO 5: CLASIFICACIÓN DE RÍOS SEGÚN CARACTERÍSTICAS OBTENIDAS

El presente capítulo se divide en dos secciones, por un lado se detallará cómo se realizó la clasificación de ríos empleando un vector de características que contenga las características obtenidas en el capítulo anterior. Por otro lado, se presentarán los métodos de evaluación de resultados empleados.

5.1 Clasificación

5.1.1 Usando Matlab

Matlab provee una herramienta que contiene distintos clasificadores según lo que se disponga a clasificar. Para ello requiere como datos de entrada una muestra donde existan las distintas clases a clasificar y su vector de característica correspondiente (hallados en el capítulo anterior) y luego calibrar los parámetros según el clasificador.

Una vez definidos los datos de entrada, se debe indicar un método de validación previo a la clasificación. Para las pruebas realizadas se selecciona el método de validación cruzada con número de divisiones igual a 5.

Para las pruebas de clasificación se utilizaron y calibraron los siguientes clasificadores:

- SVM con función de núcleo cuadrática con enfoque uno contra uno.
- SVM con función de núcleo cuadrática con enfoque uno contra el resto.
- AdaBoost con 200 iteraciones.
- AdaBoost con 1000 iteraciones.

Para una primera prueba se realizó la clasificación entre 3 clases con la siguiente distribución:

- Clase 0 "Meandros"; muestra = 40 ejemplos.
- Clase 1 "Rectos"; muestra = 40 ejemplos.
- Clase 2 "Multicanal"; muestra = 40 ejemplos (20 trenzados y 20 anastomosados).

Para una segunda prueba se realizó la clasificación entre 4 clases con la siguiente distribución:

- Clase 0 "Meandros"; muestra = 40 ejemplos.
- Clase 1 "Rectos"; muestra = 40 ejemplos.
- Clase 2 "Trenzados"; muestra = 20 ejemplos.

- Clase 3 “Anastomosados”; muestra = 20 ejemplos.

Los resultados se detallarán en la sección 5.2.

5.1.2 Usando Weka

En la etapa de experimentación con los clasificadores, se vio conveniente hacer uso de una herramienta adicional que permitiese hacer uso de más algoritmos de aprendizaje y se consideró el uso de Weka que posee una colección de algoritmos de aprendizaje de máquina, y contiene diversas herramientas para pre-procesamiento, clasificación y visualización.

Al igual que Matlab, Weka para clasificar requiere como datos de entrada una muestra donde existan las distintas clases a clasificar y su vector de característica correspondiente (hallados en el capítulo anterior) y luego calibrar los parámetros según el clasificador.

Dado que la primera prueba realizada (utilizando Matlab) obtuvo buenos resultados, se decidió enfocar el uso de Weka para realizar la clasificación sobre la misma muestra empleada para la segunda prueba (4 clases) donde la tasa de acierto no fue tan elevada. Entonces se realizó una tercera prueba con el siguiente conjunto de datos:

- Clase 0 “Meandros”; muestra = 40 ejemplos.
- Clase 1 “Rectos”; muestra = 40 ejemplos.
- Clase 2 “Trenzados”; muestra = 20 ejemplos.
- Clase 3 “Anastomosados”; muestra = 20 ejemplos.

Luego de la experimentación con distintos clasificadores, se escogió uno denominado *MultiClassClassifier*, el cual indica ser un metaclassificador que soporta conjunto de datos multiclase empleando clasificadores binarios, ya que obtuvo la mayor tasa de acierto frente a otros. El método de validación empleado previo a la clasificación fue el de *percentage split* con un 50%; es decir, tomará 50% de la muestra de datos para un entrenamiento y el otro 50% para realizar las pruebas.

Los resultados se detallarán en la sección 5.2.

5.2 Evaluación de resultados

Ambas herramientas de clasificación (Matlab y Weka) proporcionadas también ofrecen métodos de evaluación de resultados para determinar qué tan eficiente se ha realizado la clasificación. Para las tres pruebas mencionadas se

muestran sus matrices de confusión. Adicionalmente las curvas ROC de cada prueba se incluyen en el anexo.

5.2.1 Prueba 1 – SVM uno contra uno (precisión: 87.5%)

Como se puede apreciar en la figura 5.1, esta clasificación tuvo una tasa de acierto considerablemente alta y una de las razones es porque solo la clase 2 (multicanal) presenta valores positivos en su característica de bifurcaciones encontradas, lo que hace más sencillo discriminar esta clase de las otras 2.




Figura 5.1. Matriz de confusión prueba 1- SVM uno contra uno
Elaboración propia

5.2.2 Prueba 1 – SVM uno contra el resto (precisión: 90.8%)

Esta prueba, al igual que la anterior, posee una tasa de acierto considerablemente alta como se observa en la figura 5.2. Sin embargo, esta estrategia conlleva un menor costo computacional que la anterior debido a que en lugar de evaluar todas las posibles combinaciones de clases y aplicar el clasificador a cada una de ellas, esta estrategia pone cada clase contra el resto. A pesar de ello, la tasa de acierto se ve afectada un porcentaje mínimo.




Figura 5.2. Matriz de confusión prueba 1- SVM uno contra el resto
Elaboración propia

5.2.3 Prueba 1 – Adaboost con 200 iteraciones (precisión: 85%)

Esta prueba, al igual que las anteriores, posee una tasa de acierto considerablemente alta. Además, para el set de datos usados, incrementa el número de muestras de la clase 1 (rectos) clasificados erróneamente como clase 0 (meandros); sin embargo, puede identificar correctamente la totalidad de elementos pertenecientes a la clase 2 (multicanal) como se observa en la figura 5.3.

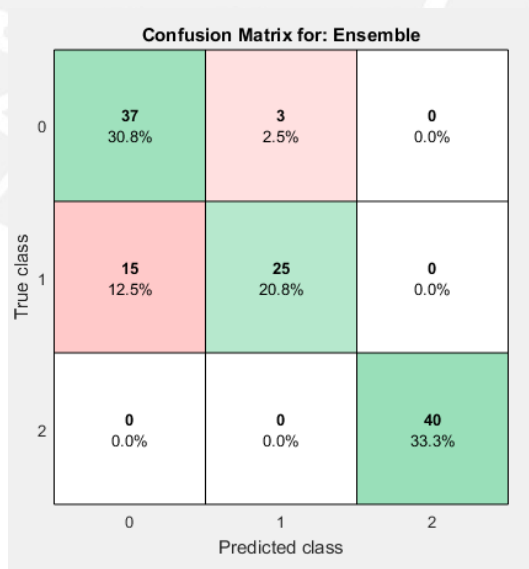


Figura 5.3. Matriz de confusión prueba 1- Adaboost con 200 iteraciones
Elaboración propia

5.2.4 Prueba 1 – Adaboost con 1000 iteraciones (precisión: 90%)

Esta prueba logra mejorar solo un poco su tasa de acierto a pesar de haber incrementado notablemente el número de iteraciones; se realizaron 5 veces más iteraciones que la prueba anterior generando un costo computacional mucho más elevado con un beneficio mínimo como se muestra en la figura 5.4. Ahora se aprecia que el número de muestras de la clase 1 (rectos) clasificados erróneamente como clase 0 (meandros) se redujo ligeramente.




Figura 5.4. Matriz de confusión prueba 1- Adaboost con 1000 iteraciones
Elaboración propia

5.2.5 Prueba 2 – SVM uno contra uno (precisión: 72.5%)

En esta prueba la clase multicanal es dividida en sus 2 subclases (trenzados y anastomosados) y la clasificación se vio afectada considerablemente debido a que no se pudo discriminar correctamente los elementos que pertenecen a la clase trenzados de los elementos que pertenecen a la clase anastomosados como se aprecia en la figura 5.6. Sin embargo, se mantiene el ratio de clasificación de las clases 0 y 1 (meandros y rectos respectivamente) respecto a la clasificación análoga de la Prueba 1.




Figura 5.6. Matriz de confusión prueba 2- SVM uno contra uno
Elaboración propia

5.2.6 Prueba 2 – SVM uno contra el resto (precisión: 70.8%)

En esta prueba, al igual que la anterior, también se vio afectada la tasa de acierto considerablemente porque no se logra identificar correctamente la clase 2 y 3 (trenzados y anastomosados respectivamente) como se muestra en la figura 5.7. Esta estrategia, como se mencionó en su análoga de la Prueba 1, supone un menor costo computacional y en este caso sí afecta el resultado.

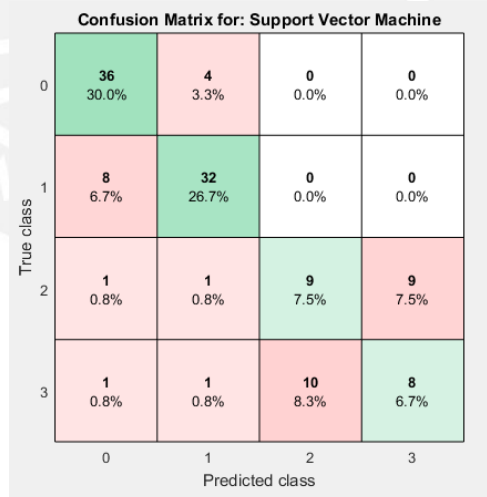


Figura 5.7. Matriz de confusión prueba 2- SVM uno contra el resto
Elaboración propia

5.2.7 Prueba 2 – Adaboost con 200 iteraciones (precisión: 50%)

Esta prueba obtuvo, junto con la siguiente, la menor tasa de acierto para la clasificación. Además, se observa que el total de las clases 1 y 3 (rectos y

anastomosados respectivamente) fueron clasificados erróneamente como se aprecia en la figura 5.8.

True class \ Predicted class	0	1	2	3
0	40 33.3%	0 0.0%	0 0.0%	0 0.0%
1	40 33.3%	0 0.0%	0 0.0%	0 0.0%
2	0 0.0%	0 0.0%	20 16.7%	0 0.0%
3	0 0.0%	0 0.0%	20 16.7%	0 0.0%

Figura 5.8. Matriz de confusión prueba 2- Adaboost con 200 iteraciones
Elaboración propia

5.2.8 Prueba 2 – Adaboost con 1000 iteraciones (precisión: 50%)

Esta prueba realiza 5 veces más iteraciones que la anterior generando un mayor costo computacional; sin embargo, logra el mismo resultado que la prueba anterior: el total de las clases 1 y 3 (rectos y anastomosados respectivamente) fueron clasificados erróneamente como se aprecia en la figura 5.9.

True class \ Predicted class	0	1	2	3
0	40 40.0%	0 0.0%	0 0.0%	0 0.0%
1	20 20.0%	0 0.0%	0 0.0%	0 0.0%
2	0 0.0%	0 0.0%	20 20.0%	0 0.0%
3	0 0.0%	0 0.0%	20 20.0%	0 0.0%

Figura 5.9. Matriz de confusión prueba 2- Adaboost con 1000 iteraciones
Elaboración propia

5.2.9 Prueba 3 – MultiClassClassifier (80%)

Como se puede apreciar en la figura 5.10, esta clasificación tuvo una tasa de acierto elevada debido a que puede clasificar correctamente la mayoría de los ríos que pertenecen a las clases de meandros y rectos, y ninguna de las

anteriores es clasificada erróneamente como trezada o anastomosada. Sin embargo, todavía existen problemas para identificar eficientemente cuándo un río pertenece a la clase trezada y cuándo pertenece a la anastomosada.

Confusion Matrix for: Ensemble

True class	0	21 35.0%	0 0.0%	0 0.0%	0 0.0%
	1	6 10.0%	16 26.7%	0 0.0%	0 0.0%
	2	1 1.7%	0 0.0%	5 8.3%	2 3.3%
	3	0 0.0%	0 0.0%	3 5.0%	6 10.0%
		0	1	2	3
		Predicted class			

Figura 5.10. Matriz de confusión prueba 3- MultiClassClassifier
Elaboración propia

5.3 Aplicación del modelo predictivo

Una vez realizadas las pruebas, se seleccionó el clasificador que tuvo la mayor tasa de acierto en su clasificación y se probó el modelo obtenido tomando como dato de entrada una nueva imagen de río esqueletizada que no haya formado parte de los datos con los cuales se entrenó a la herramienta. El clasificador seleccionado fue el de la prueba 3: *MultiClassClassifier*.

La imagen utilizada para la prueba del modelo es la que se observa en la figura 5.11 que pertenece a un río de clase meandro.




Figura 5.11. Imagen de un río meandro (izquierda) y su Esqueletización (derecha).

Elaboración propia

Al utilizar el modelo para determinar qué clase de río representaba, se obtuvo una clasificación satisfactoria, debido a que se le clasificó correctamente como un río de clase meandro. En la figura 5.12 se observan los resultados obtenidos.

```

=== Summary ===

Correctly Classified Instances      1      100  %
Incorrectly Classified Instances    0       0  %
Kappa statistic                    1
Mean absolute error                0.1409
Root mean squared error            0.1936
Total Number of Instances          1

=== Detailed Accuracy By Class ===

          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
          1,000  0,000  1,000     1,000  1,000     0,000   ?        1,000    Meandro
          0,000  0,000  0,000     0,000  0,000     0,000   ?        ?        Recto
          0,000  0,000  0,000     0,000  0,000     0,000   ?        ?        Trenzado
          0,000  0,000  0,000     0,000  0,000     0,000   ?        ?        Anastomosado
Weighted Avg.  1,000  0,000  1,000     1,000  1,000     0,000  0,000  1,000

=== Confusion Matrix ===

a b c d  <-- classified as
1 0 0 0 | a = Meandro
0 0 0 0 | b = Recto
0 0 0 0 | c = Trenzado
0 0 0 0 | d = Anastomosado

```

Figura 5.12. Predicción hecha por el modelo desarrollado. Se clasificó correctamente un río de tipo meandro.
Elaboración propia

CAPÍTULO 6: CONCLUSIONES Y TRABAJOS FUTUROS

6.1 Conclusiones

En el presente proyecto se ha estudiado y desarrollado un prototipo para la caracterización y clasificación de ríos en imágenes satelitales que han sido previamente procesadas, donde se logró obtener su esqueleto. Dicho esqueleto, a través del análisis realizado del mismo, permitió obtener distintas características con las cuales se realizaría la clasificación. A continuación, se presentan las conclusiones obtenidas a lo largo del desarrollo del prototipo.

Inicialmente, se consideró usar como características a los aspectos morfológicos fácilmente identificables como área, perímetro, convexidad, redondez, etc. Sin embargo, estos no brindaban una información lo suficientemente cuantitativa como para que se pueda realizar una clasificación eficiente.

Dado que el esqueleto del río es similar a la forma que poseen las nervaduras de las hojas, se determinó viable utilizar una metodología de caracterización (dimensión fractal multi-escala) realizada a las últimas donde se obtuvo una tasa de acierto elevada y adaptarla para la caracterización del esqueleto de los ríos. Las características obtenidas por la metodología anterior dieron buenos resultados en la identificación de ríos que presentan un único canal (meandros y rectos). Adicionalmente, se consideró utilizar el número de bifurcaciones que presenta el esqueleto como una característica adicional y con ello se pudo diferenciar correctamente 3 clases: meandros, rectos y multicanal. Sin embargo, existen problemas para identificar las clases contenidas dentro del grupo de multicanal. Como se observa en las pruebas, las características utilizadas no son suficientes para la clasificación correcta de las 4 clases de ríos y se considera viable utilizar el borde de estos para identificar nuevas características que permitan diferenciar mejor las clases.

6.2 Trabajos futuros

Con el fin de poder mejorar los aspectos que no pudieron ser cubiertos en este proyecto, en esta sección se proponen algunas ideas que pueden ser realizadas para mejorar la investigación realizada.

- Desarrollo e integración del módulo que permita la correcta detección y esqueletización de ríos contenidos en imágenes satelitales.
- Utilizar esta investigación como base para un desarrollo de una herramienta computacional que pueda detectar, en base al tipo de río y cómo evoluciona su caudal en el tiempo, posibles zonas donde puede ocurrir una inundación por fenómenos naturales (desbordamiento del río).



REFERENCIAS BIBLIOGRÁFICAS

- Belkacem-Boussaid, K., Sertel, O., Lozanski, G., Shana'aah, A., & Gurcan, M. (2009, 3-6 Sept. 2009). Extraction of color features in the spectral domain to recognize centroblasts in histopathology. Paper presented at the Engineering in Medicine and Biology Society, 2009. EMBC 2009. Annual International Conference of the IEEE.
- Ben-Hur, A., & Weston, J. (2010). A User's Guide to Support Vector Machines. En O. Carugo, & F. Eisenhaber, Data Mining Techniques for the Life Sciences, Methods in Molecular Biology. Humana Press.
- Bennett, M.A 1987. Rapid monitoring of wetland water status using density slicing. Proceeding of the 4th Australian Remote Sensing Conference 14-18 September (1987), Adelaide: 682-691.
- Bishop, C.M. (2006). Pattern recognition and machine learning: Springer.
- Chapelle, O. (1998). Support Vector Machines for Image Classification. Redbank, NJ, USA: Image Processing Research Department, AT&T.
- Fawcett, T. (2005). An introduction to ROC analysis. Science Direct, 861-874.
- Feng Zhao & Xiaou Tang. (2006). Preprocessing and postprocessing for skeleton-based fingerprint minutiae extraction
- Frazier, P., and K., J. Page. (2000). Water Body Detection and Delineation with Landsat TM Data. Photogrammetric Engineering & Remote Sensing 66(12) (2000): 1461-1467.
- Freund, Yoav, & Schapire, Robert E. (1997). A decision-theoretic generalization of online learning and an application to boosting. Journal of computer and system sciences, 55(1), 119-139.
- Gonzales, Rafael C., & Woods, Richard E. (2008). Digital Image Processing (Third Edition ed.). United States of America: Pearson Education, Inc.

- Huggett, Richard J. (2007). *Fundamentals of Geomorphology (Second Edition ed.)*:
Routledge
- Johnston, R, and M. Barson (1993). Remote sensing of Australian wetlands: An evaluation of Landsat TM data for inventory and classification. *Australian Journal of Marine and Freshwater Research* 44 (1993): 235-252.
- Klemenjak, S., Waske, B., Valero, S., & Chanussot, J. (2012). Automatic Detection of Rivers in High-Resolution SAR Data. *Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of*, 5(5), 1364-1372. doi: 10.1109/JSTARS.2012.2189099
- Kohavi, R. (1995). *A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection*. Stanford, CA: Computer Science Department, Stanford University
- Koenderink, J. (2010). *Computer Vision: Detection, Recognition and Reconstruction*. Computer Vision. R. Cipolla, S. Battiato and G. Farinella, Springer Berlin Heidelberg. 285.
- Manavalan, P., P. Sathyanath, and G., T. Rajegowda (1993). Digital image analysis techniques to estimate waterspread for capacity evaluations of reservoirs .. *Photogrammetric Engineering & Remote Sensing* 59: 1389-1395.
- Marsland, Stephen. (2009). *Machine Learning: An Algorithmic Perspective*. United States of America: CRC Press LLC.
- Morse, A., T., J. Zarriello, and W., J. Kramber (1990). Using remote sensing and GIS technology to help adjudicate Idaho water rights. *Photogrammetric Engineering & Remote Sensing* 56: 365-370.
- Picard RR, Berk KN. Data splitting. *Am Statistician* 1990;44:140–7.

- Plotze, R., Falvo, M., Gomes Pádua, J., Bernacci, L., Carneiro Vieira, M., Oliveira G., and Martinez Bruno O. (2005). Leaf shape analysis using the multiscale Minkowski fractal dimension, a new morphometric method: a study with *Passiflora* (Passifloraceae)
- Roiger, R., & Geatz, M. (2003). Data Mining: A Closer Look. En R. Roiger, & M. Geatz, *Data Mining, A Tutorial-based Primer* (págs. 33-65). Pearson Education.
- Rosgen, D.L. (1994) A classification of natural rivers
- Russ, Jhon C. (1999). *The Image Processing Handbook* (Third Edition ed.). United States of America: CRC Press LLC.
- Sadoff, Claudia & Muller, Mike (2009). *Water Management, Water Security and Climate Change Adaptation: Early Impacts and Essential Responses*.
- Shaikh, M., A. Brady, and P. Sharma (1997). Application of remote sensing to assess wetland inundation and vegetation response in relation to hydrology in the Great Cumbung Swamp, Lachlan Valley, NSW, Australia. *Wetland for the Future*: 595-606.
- Shrestha, R., & Liping, D. (2013, 12-16 Aug. 2013). Land/water detection and delineation with Landsat data using Matlab/ENVI. Paper presented at the *Agro-Geoinformatics (Agro-Geoinformatics), 2013 Second International Conference on*.
- Smith, L.C. (1997). Satellite remote sensing of river inundation area, stage, and discharge: A review. *Hydrological Processes* 11: 1427-1439.
- Smith L.C., Turcotte D.L. & Isacks B.L. (1998). Stream flow characterization and feature detection using a discrete wavelet transform
- Sonka, Milan, Hlavac, Vaclav, & Boyle, Roger. (2008). *Image Processing, Analysis, and Machine Vision* (Third Edition ed.): Thomson.

- Soo-Chang, Pei, & Ching-Min, Cheng. (1999). Color image processing by using binary quaternion-moment-preserving thresholding technique. *Image Processing, IEEE Transactions on*, 8(5), 614-628. doi: 10.1109/83.760310
- Sucar, L. E. (2008). *Visión Computacional*. Puebla, México, Instituto Nacional de astrofísica, Óptica y Electrónica.
- Thorley, N, S. Clandillon, and P. De Fraipont 1997. The contribution of spaceborne SAR and optical data in monitoring flood events: Example in northern and southern France. *Hydrological Processes II (1997)*: 1409-1413.
- van Leeuwen, J. (2004). *Approaches in Machine Learning*. En *Algorithms in Ambient Intelligence*. Philips Research Book Series.
- Wei-Ta, Chen, Wei-Chuan, Liu, & Ming-Syan, Chen. (2010). Adaptive Color Feature Extraction Based on Image Color Distributions. *Image Processing, IEEE Transactions on*, 19(8), 2005-2016. doi: 10.1109/TIP.2010.2051753
- Zhao, Zhang, Mingbo, Zhao, Bing, Li, & Peng, Tang. (2013, 4-9 Aug. 2013). ColorPCA: Color principal feature extraction technique for color image reconstruction and recognition. Paper presented at the Neural Networks (IJCNN), The 2013 International Joint Conference on.
- Zhifang, L., Shulian, W., Shoudong, C., & Hui, L. (2009, 17-19 Oct. 2009). Segment and Feature Extraction of Optical Coherence Tomography Image of Mouse's Skin In Vivo Using Mathematical Morphology. Paper presented at the Biomedical Engineering and Informatics, 2009. BMEI '09. 2nd International Conference on.