



**UNIVERSIDAD DE CHILE
FACULTAD DE CIENCIAS FÍSICAS Y MATEMÁTICAS
DEPARTAMENTO DE INGENIERÍA CIVIL**

**PRONÓSTICO DE VOLÚMENES DE DESHIELOS MEDIANTE REDES
NEURONALES RECURRENTE E IMÁGENES SATELITALES MODIS**

**TESIS PARA OPTAR AL GRADO DE MAGÍSTER EN CIENCIAS DE LA
INGENIERÍA, MENCIÓN RECURSOS Y MEDIO AMBIENTE HÍDRICO**

MEMORIA PARA OPTAR AL TÍTULO DE INGENIERO CIVIL

MAURICIO ANDRÉS CARTES VALDIVIA

**PROFESOR GUÍA:
XIMENA VARGAS MESA**

**MIEMBROS DE LA COMISIÓN:
JAMES MCPHEE TORRES
LUDWIG STOWHAS BORGHETTI**

**SANTIAGO DE CHILE
MAYO 2009**

RESUMEN

En la actualidad, los recursos hídricos son cada día más escasos para las diferentes actividades económicas a lo largo de Chile. Una de las principales fuentes de agua la constituyen aquellas provenientes del derretimiento de nieves, acumuladas estacionalmente en la cordillera de Los Andes, por lo que conocer la magnitud de la nieve acumulada, su distribución espacial y temporal, es de suma importancia para determinar la disponibilidad de agua en la temporada de deshielo.

El principal objetivo de este trabajo es evaluar la oferta de agua disponible en las zonas cordilleranas durante la temporada estival a escala semanal, mediante una herramienta capaz de pronosticar la escorrentía superficial a partir de análisis remoto unido a elementos de inteligencia artificial, que proporcione resultados con un error menor al 10%, entre el volumen de agua observado y pronosticado. Como objetivo secundario se busca: (i) entender la evolución de la cobertura de nieve, en la búsqueda de patrones de comportamiento según año hidrológico, (ii) analizar la relación entre la cobertura de nieve y la escorrentía producto de los deshielos, (iii) evaluar las ventajas y desventajas del uso de redes neuronales artificiales como herramienta de pronóstico. La región en estudio corresponde a la zona alta de las cuencas de los ríos Aconcagua y Maipo. En ella se seleccionaron 6 cuencas de acuerdo al régimen de escorrentía y disponibilidad de información fluviométrica. La información empleada corresponde a imágenes satelitales MODIS (MOD09) y registros fluviométricos diarios. El período de análisis estuvo acotado a la disponibilidad de las imágenes MOD09, con un total de 359 imágenes (cada 8 días) entre el año 2000 y el año 2007.

Para la discriminación de la cobertura de nieve se empleó el Índice de Diferenciación de Nieve Normalizado (NDSI). Uno de los mayores problemas en el empleo del NDSI corresponde a la selección del umbral apropiado, como indicador de la presencia de nieve. La conjunción de criterios estadísticos en conjunto con aspectos remotos cualitativos-cuantitativos, representó una opción para el manejo de este tipo de información, concluyéndose que un umbral $NDSI = 0.7$, para cualquier época del año, representaba la mejor alternativa como elemento discriminatorio. El análisis continuo de la cobertura nival permitió explicar diferentes elementos de la hidrología de nieves tales como: (i) desfase con la escorrentía de deshielo, (ii) área máxima y mínima de cobertura y (iii) efecto del período de acumulación sobre el volumen de escorrentía. El desfase temporal observado entre la disminución de la cobertura de nieve y la escorrentía media, puede ser explicado por la existencia de flujos sub-superficiales.

Los resultados de la calibración indicaron que las redes neuronales recurrentes representan una alternativa para la modelación de la escorrentía de deshielo, puesto que la información de entrada posee un carácter errático capaz de ser captado por la red. Sin embargo, la búsqueda de una arquitectura apropiada representó un tedioso trabajo debido a la gran variedad de arquitecturas susceptibles de ser planteadas. El análisis efectuado permitió distinguir al número de series de entrada y al desfase temporal entre las series remotas como aquellos elementos de mayor sensibilidad. La determinación de un modelo diferente para cada cuenca está asociada a las desiguales características que posee cada una. La validación da cuenta de la inestabilidad que presentan los diferentes modelos para las 6 cuencas en estudio, producto de la información de entrada.

El pronóstico generado para una ventana de 5 meses (Septiembre-2007/Enero-2008) muestra una baja incertidumbre en el pronóstico mensual, sin embargo, el error absoluto promedio es superior al 10%. Se concluye que este tipo de herramientas puede ser ventajosa de usar en el futuro, en la medida que exista un mayor número de registros satelitales o de otras fuentes de información con amplios registros temporales. Finalmente, se sugiere un pre-procesamiento más elaborado de la información remota que otorgue una mayor estabilidad de las señales vistas individualmente.

AGRADECIMIENTOS

Mi memoria es débil y puede que no recuerde algunas personas que fueron parte de este trabajo noble.

En primer lugar deseo agradecer a mi profesora Ximena Vargas, por su apoyo, su educación y su amistad, elementos que me han hecho crecer enormemente. Un apoyo de origen desconocido corresponde al profesor James McPhee, con quien he podido compartir y discutir parte de este estudio, las gracias por su interés en el área y el apoyo constante. También deseo manifestar mi gratitud al profesor Ludwig, por su colaboración en el desarrollo final de este trabajo, sus consejos y sus críticas.

Una de las personas que apoyó constructivamente mi trabajo, no pudo estar presente en la finalización de éste. Mis más sinceros agradecimientos en el más allá al académico Raúl Aguilera, y sus “vueltas de carnero”.

Muchos amigos del ayer y del hoy han sido parte de mi historia, y no puedo dejar de recordar sus palabras de aliento, sus ayudas y sus comentarios en este período de formación. La lista es enorme y comienzo con: Jessica, Mónica y Sra. Gaby, de nuestra división; la familia Muñoz (Rubén y Pamela) por compartir parte de esta inquietud; amigas lejanas y cercanas desde el año 1, Ha Nui, Magali, Kathleen y Josefina; amigos de civil (cemento), Abelardo y Eloy; amigas de hidráulica, Bárbara y Carolinas. También recuerdo a compañeros del magíster como René, Felipe (Shagy) y Schuster, con los cuales me formé en la última recta. Otros que aún están en la nebulosa: Carlos, Francisco, Aldo, Pablo, Nivaldo y Fernanda, gracias por su apoyo. No puedo olvidar a un grupo de personas con las cuales compartí un libro, un diario y una taza de té: Rosita, Mariana, Carolina, Paty, Lily, Jovy, Gabriel y Claudia (de la Biblioteca). Amigos fundamentales (parte de mi vida) en estos últimos años son causa de mi admiración: Cristóbal (Coso), Claudia y Tania, todas las gracias por ser como son, simples y especiales. Amigos fundamentales que te dan confianza: Rodrigo, Daniela y Eduardo que con cada palabra demuestran su sapiencia indiscutible, gracias por sus palabras de valor.

Finalmente deseo agradecer a mis padres, Francisco y Alejandra, por su entrega incondicional en mi formación desde el día 0.

A mi padre, a mi madre y
a mi primer amor.

ÍNDICE DE CONTENIDOS

CAPÍTULO I INTRODUCCIÓN	7
1.1. INTRODUCCIÓN	7
1.2. OBJETIVOS	8
1.3. ORGANIZACIÓN DE ESTE INFORME	8
CAPÍTULO II REVISIÓN BIBLIOGRÁFICA	10
2.1. INTRODUCCIÓN	10
2.2. HIDROLOGÍA DE NIEVES	11
2.2.1. ALMACENAMIENTO	13
2.2.2. DERRETIMIENTO	13
2.2.3. GENERACIÓN DE LA ESCORRENTÍA DE DESHIELO	13
2.3. PERCEPCIÓN REMOTA	14
2.3.1. ELEMENTOS DE PERCEPCIÓN REMOTA	15
2.3.2. USO DE IMÁGENES SATELITALES EN LA MODELACIÓN DE LA ESCORRENTÍA DE DESHIELO	15
2.3.3. IMÁGENES SATELITALES MODIS	16
2.3.4. DETECCIÓN DE ELEMENTOS CON/SIN NIEVE	17
2.3.5. DIFERENCIACIÓN DE ELEMENTOS CON NIEVE	18
2.3.6. MODIS SURFACE REFLECTANCE (MOD09)	19
2.3.7. MODIS SNOW-COVER (MOD10)	20
2.3.8. VALIDACIÓN GENERAL DE LAS IMÁGENES MODIS	21
2.4. REDES NEURONALES	21
2.4.1. NEURONA ARTIFICIAL	22
2.4.2. REDES NEURONALES DE MÚLTIPLES CAPAS	23
2.4.3. REDES NEURONALES RECURRENTE	24
2.4.4. REDES NEURONALES RECURRENTE DINÁMICAS	24
2.4.5. ALGORITMO BACKPROPAGATION Y FILTRO FIR	25
2.4.6. PREDICCIÓN CON UN MODELO NEURONAL ARTIFICIAL	26
2.5. EVALUACIÓN ESTADÍSTICA DE LOS RESULTADOS DEL MODELO	27
2.5.1. CONCEPTOS ESTADÍSTICOS BÁSICOS	27
2.5.2. DIAGNÓSTICO DEL MODELO	28
CAPÍTULO III ZONA DE MODELACIÓN	30
3.1. CARACTERIZACIÓN DE LA ZONA DE ESTUDIO	30
3.2. CLIMA DE LA REGIÓN	31
3.3.1. CLIMA TEMPLADO MEDITERRÁNEO	31
3.3.2. CLIMA FRÍO DE ALTURA	32
3.3.3. VARIABILIDAD CLIMÁTICA FUTURA	32
3.3. INFORMACIÓN FLUVIOMÉTRICA	32
3.3.1. CURVAS DE VARIACIÓN ESTACIONAL	32
3.3.2. INFORMACIÓN DISPONIBLE	37
CAPÍTULO IV ANÁLISIS DE LA INFORMACIÓN SATELITAL	41

4.1. SELECCIÓN DE IMÁGENES	41
4.2.1. VALIDACIÓN PUNTUAL DE LAS IMÁGENES	41
4.2.2. REGISTRO DE IMÁGENES A UTILIZAR	42
4.2. PROCESAMIENTO DE LAS IMÁGENES: COBERTURA NIVAL	43
4.2.1. RELACIÓN ENTRE LA COBERTURA DE NIEVE Y LA ESCORRENTÍA DE DESHIELO	44
4.2.2. DESFASE TEMPORAL ENTRE LA COBERTURA DE NIEVE Y LA ESCORRENTÍA DE DESHIELO	48
4.2.3. BÚSQUEDA DE UN MODELO LINEAL ENTRE COBERTURA DE NIEVE Y LA ESCORRENTÍA DE DESHIELO	52
4.2.4. ESTUDIO DE TRANSECTAS PARA LA BÚSQUEDA DE PATRONES DE COMPORTAMIENTO	59
4.2.5. RELACIÓN ENTRE COBERTURA DE NIEVE Y TEMPERATURA DE ALTURA	64

CAPÍTULO V ESTRUCTURA DEL MODELO DE SIMULACIÓN DE REDES NEURONALES 67

5.1. PRE-PROCESAMIENTO Y POST-PROCESAMIENTO DE LA INFORMACIÓN	67
5.2. ESTRUCTURA GENERAL DEL MODELO	68
5.3. CONFIGURACIONES PARA LA SELECCIÓN DE LA INFORMACIÓN	69
5.3.1. ELECCIÓN DE PÍXELES AL AZAR	70
5.3.2. ELECCIÓN DE PÍXELES SISTEMÁTICO AL AZAR SEGÚN TOPOGRAFÍA	71
5.3.3. ELECCIÓN DE PÍXELES SISTEMÁTICO AL AZAR SEGÚN COBERTURA	72
5.3.4. ELECCIÓN DE PÍXELES EN LA TRANSECTA CENTRAL	74
5.4. ARQUITECTURA DE LA RED	75
5.5. ENTRENAMIENTO	76
5.5.1. VARIACIÓN UNIDADES CAPA DE ENTRADA	76
5.5.2. VARIACIÓN UNIDADES CAPA OCULTA	82
5.5.3. RETARDO TEMPORAL DE LAS CAPAS	82
5.5.4. INCLUSIÓN DESFASE TEMPORAL ENTRE SERIES DE TIEMPO	84
5.5.5. INCLUSIÓN DE SERIE DE PORCENTAJE DE ÁREA CUBIERTA	87
5.6. VALIDACIÓN DE LOS RESULTADOS	89

CAPÍTULO VI PRONÓSTICO DEL VOLUMEN NIVAL 92

6.1. INTRODUCCIÓN	92
6.2. RESULTADOS	92
6.2.1. ESTACIÓN RÍO JUNCAL EN JUNCAL	93
6.2.2. ESTACIÓN RÍO VOLCÁN EN QUELTEHUES	97
6.2.3. ESTACIÓN RÍO MAIPO EN LAS HUALTATAS	101

CAPÍTULO VII CONCLUSIONES 106

7.1. COMENTARIOS ACERCA DE LA INFORMACIÓN REMOTA	106
7.2. COMENTARIOS ACERCA DEL ANÁLISIS DE LA INFORMACIÓN SATELITAL	107
7.3. COMENTARIOS ACERCA DEL MODELO	107
7.4. RESULTADOS DEL MODELO	108
7.5. CONCLUSIONES GENERALES	108
7.6. RECOMENDACIONES	109

CAPÍTULO VIII REFERENCIAS 110

<u>ANEXOS</u>	<u>114</u>
<u>ANEXO I VALIDACIÓN PUNTUAL DE LAS IMÁGENES</u>	<u>114</u>
<u>ANEXO II PREPROCESAMIENTO DE LAS IMÁGENES MODIS MOD09</u>	<u>119</u>
<u>ANEXO III RESUMEN RESULTADOS ENTRENAMIENTO</u>	<u>124</u>

CAPÍTULO I INTRODUCCIÓN

1.1. INTRODUCCIÓN

Históricamente la modelación de la cobertura nival se ha abordado a través de modelos concentrados, los cuales se ajustan para modelar un punto específico y, mediante estimaciones lineales y regresiones estadísticas, se obtiene una representación agregada del manto en su conjunto constituyendo la extrapolación de una simulación puntual. Según la WMO (*World Meteorological Organization*), el equivalente en agua es la variable más importante en los modelos de escorrentía de deshielo ya que por medio de ésta es posible determinar los volúmenes de agua disponibles en el manto nival (WMO, 1986; WMO, 1992). La temperatura del aire, la precipitación y el área cubierta de nieve representan las variables de mayor uso en la determinación del equivalente en agua y, por lo tanto, pueden ser consideradas como las de mayor relevancia bajo este enfoque.

En la década de los 90 la modelación de nieves evolucionó hacia el tipo distribuido debido a la información disponible y las capacidades computacionales ya existentes sumado a las nuevas metodologías del conocimiento remoto. En países como los Estados Unidos de Norteamérica, se han desarrollado modelos de simulación nival en “tiempo real” pero orientados al manejo forestal, y no desde el punto de vista puramente hidrológico. La experiencia de estos modelos en el país del norte ha llegado a buen fin por la disponibilidad de datos meteorológicos, y morfológicos a la escala de simulación (Wigmosta, 1994).

Los modelos distribuidos necesitan una cantidad de información muy elevada comparado con los modelos concentrados, la cual estará sujeta a la resolución espacial en la que se está simulando el proceso. En Chile se dispone de información medida en determinados puntos e información meteorológica espacialmente distribuida a distintas resoluciones espaciales. En el país, uno de los primeros modelos del tipo distribuido fue desarrollado en el Departamento de Ingeniería Civil de la Universidad de Chile (Valck, 2004) con interesantes resultados en la cuenca del río Maule. El modelo planteado utilizó información del modelo de pronóstico meteorológico MM5/DGF a escala horaria y fue validado para el año 2002 mediante imágenes tipo MODIS y registros hidrométricos. Limitaciones como disponibilidad de información en tiempo real unido a la falta de una red de monitoreo para variables meteorológicas en la alta cordillera dificultan el empleo de este modelo para su uso generalizado.

Ante este escenario, la concepción de un nuevo modelo para la simulación y el pronóstico de la escorrentía en cuencas de régimen nival se basa en buscar una relación que permita conocer de forma indirecta el caudal de deshielo susceptible de generarse luego de una nevada sin necesidad de involucrar mediciones de altura o densidad del manto. La hidrología de nieves indica que la generación de la escorrentía de deshielo responde a un fenómeno en el que participan factores de diferente naturaleza, que están relacionadas entre sí y que tienen diferentes grados de influencia en la respuesta final. Es por este motivo que, en la búsqueda de un modelo de pronóstico, será básico poder incorporar aquellos factores que influyen de manera preponderante sobre este proceso.

La implementación de una herramienta versátil que pueda ser aplicada en otros lugares del mundo privados de monitoreo a grandes alturas y que permita estimar los volúmenes de escorrentía mediante información distribuida o semi-distribuida representa el mayor desafío de esta investigación. El uso de información remota en tiempo real como única variable de entrada representa una alternativa para este tipo de planteamiento en cuencas controladas puesto que a la fecha existen variados registros satelitales de bajo costo que pueden ser utilizados en su conjunto. El resultado a la búsqueda de herramientas que permitan reconocer ciertas características del manto de nieve sugiere el empleo de técnicas artificiales aplicadas al reconocimiento de patrones.

En el presente trabajo se emplearon redes neuronales artificiales para encontrar una relación entre la escorrentía de deshielo y el manto de nieve caracterizado a partir de registros satelitales. Dicha relación fue planteada como un reconocimiento de patrones sobre múltiples series de tiempo.

1.2. OBJETIVOS

El principal objetivo de este trabajo es evaluar la oferta de agua disponible en las zonas cordilleranas durante la temporada estival a escala semanal. Para ello se plantea la generación de una herramienta capaz de pronosticar el volumen de agua almacenado en el manto nival a partir de análisis remoto unido a elementos de inteligencia artificial, que proporcione resultados con un error menor al 10%.

Como objetivo secundario se busca entender algunos procesos asociados a la hidrología de nieves a nivel de cuenca, mediante el empleo del análisis remoto sobre un conjunto de registros satelitales, que permita entender la variabilidad espacial de la cobertura nival observada con la escorrentía superficial generada por los deshielos.

Otro de los objetivos secundarios es evaluar las ventajas y desventajas del uso de redes neuronales artificiales en la búsqueda de una relación entre las variables que permita generar un pronóstico de caudales de deshielos en tiempo real. Para ello se plantea el uso de registros satelitales como información de entrada y registros fluviométricos como información de comparación a la salida del modelo de red neuronal.

Otros objetivos importantes de destacar son:

- Crear una herramienta versátil para el pronóstico de volúmenes de deshielo en base a información remota disponible a nivel mundial e información fluviométrica.
- Aplicar la metodología de percepción remota para monitorear la dinámica del manto de nieve en la cordillera.
- Entender ciertos aspectos de la hidrología de nieves que no han sido explicados con rigurosidad.
- Aplicar la metodología de redes neuronales sobre múltiples series de tiempo.
- Evaluar el uso de redes dinámicas temporales para la modelación de la escorrentía de deshielo.

1.3. ORGANIZACIÓN DE ESTE INFORME

A continuación se describe brevemente cada capítulo que conforma la presente investigación.

La investigación desarrollada demandó una extensa revisión bibliográfica para entender la dinámica de los procesos físicos del manto de nieve, las bases de la modelación de la hidrología de nieves que incluye los últimos trabajos en Chile, además de diferentes investigaciones realizadas alrededor del mundo en torno al empleo de información remota, y técnicas artificiales para el análisis de series de tiempo. Esto se explicita en el Capítulo I.

En el Capítulo II, referente a la revisión bibliográfica, se mencionan diferentes relaciones en torno a la evolución del manto de nieve y su relación con la escorrentía. Se explica la metodología que existe detrás del análisis remoto y su empleo para la discriminación de la nieve. Además, se describen las cualidades de las imágenes a utilizar y las propiedades de las redes neuronales recurrentes. Finalmente se señalan las relaciones matemáticas usualmente utilizadas para la evaluación de modelos de redes neuronales.

En el Capítulo III, referente a la zona de estudio, se sintetizan algunas características de la región de estudio en torno al clima y régimen de escorrentía. Se muestran los registros fluviométricos disponibles para las 6 sub-cuencas seleccionadas en el presente estudio.

En el Capítulo IV, referente al análisis de las imágenes satelitales, se presenta la metodología empleada sobre cada imagen y, los resultados obtenidos de este procesamiento y su relación con la evolución anual del manto de nieve. Además, se muestran las relaciones entre la escorrentía de deshielo y la cobertura nival obtenidas para cada cuenca, abordadas como series de tiempo. Finalmente se explica el potencial uso de transectas para el entendimiento de la evolución del manto y, la relación entre la temperatura de altura y la cobertura de nieve.

En el Capítulo V, referente a la modelación propiamente tal, se describe la metodología empleada en la elaboración del modelo, asociadas a las diferentes esquemas de selección de información y a los diferentes esquemas de arquitectura de la red neuronal. A partir de los resultados de la validación define un modelo único para el conjunto de cuencas o para cada cuenca en estudio.

En el Capítulo VI, referente al pronóstico del modelo, se muestran los resultados obtenidos para el período 2007-2008 en 3 de las 6 cuencas seleccionadas.

En el Capítulo VII, referente a las conclusiones y recomendaciones, se hace un análisis crítico a los alcances de la modelación y los resultados obtenidos. Además, se señalan algunas recomendaciones acerca del empleo de imágenes, series de tiempo múltiples y redes neuronales dinámicas.

CAPÍTULO II REVISIÓN BIBLIOGRÁFICA

2.1. INTRODUCCIÓN

El comportamiento de la escorrentía en cuencas ubicadas en la zona cordillerana está sujeta directamente a la evolución y calidad del manto de nieve que cubre la cuenca aportante además de otras variables. Elementos fisiográficos y meteorológicos, entre otros, afectan la evolución del manto de nieve generándose una acumulación y disgregación variable durante el año.

En determinadas regiones del planeta, el manto de nieve puede entenderse como un almacenamiento de agua en la cordillera que sirve para abastecer de recursos hídricos al valle durante el período de deshielo. El período de almacenamiento se desarrolla generalmente durante las épocas de otoño e invierno, en tanto que el período de deshielo se desarrolla durante los meses más cálidos del año. En la zona central de Chile, el agua que se genera por el derretimiento de las nieves posee una variabilidad estacional, encontrándose bajos caudales durante otoño e invierno y altos caudales durante los meses restantes. En otro aspecto, el manto de nieve resulta ser altamente sensible a los cambios climáticos (Barnett *et al.*, 1989; Cess *et al.*, 1991; Cohen and Entekhabi, 2001), por lo que puede ser considerado como un indicador del calentamiento global (Gupta, R. *et al.*, 2005).

La estimación de la cobertura nival representa sin dudas un elemento básico en la hidrología de nieves porque permite estimar los recursos hídricos disponibles en la cordillera. La medición de esta variable resulta ser muy dificultosa ya que los métodos convencionales de medición poseen limitaciones en el monitoreo a grandes alturas debido a la topografía accidentada y a las condiciones climáticas adversas. En esta perspectiva, las imágenes satelitales resultan ser una herramienta poderosa al proveer información de la cobertura nival en la alta cordillera a intervalos regulares de tiempo. Los mapas de cobertura nival fueron una de las primeras aplicaciones de percepción remota (Tarble, 1963; Dozier, 1989). Desde entonces, los análisis de este tipo han evolucionado acorde a la disponibilidad de imágenes, área de captura, resolución espectral y temporal de las imágenes.

La información remota ha sido ampliamente estudiada en diferentes aspectos tanto cualitativos como cuantitativos de manera de asociar alguna característica medible de la nieve a ésta. En esta perspectiva cabe destacar el trabajo realizado por Gupta *et al.*, (2005) en torno a la diferenciación entre nieve “seca” y nieve “húmeda” en imágenes de multi-espectro IRS y la investigación de Molotch *et al.*, (2004) para discriminar el equivalente en agua a partir de imágenes AVHRR (Advanced Very High Resolution Radiometer).

Ante la necesidad de generar una herramienta capaz de pronosticar los volúmenes de deshielo, a partir de la unificación entre aspectos cualitativos y cuantitativos, se ha convergido hacia el área de la inteligencia artificial, donde las redes neuronales han conseguido combinar estos aspectos.

La predicción de un fenómeno inestable en el tiempo puede incluir la variable en cuestión además de información asociada a ésta. La escorrentía de deshielo asociada al manto de nieve, unido a información remota del manto, puede ser abordada mediante el procesamiento de señales múltiples.

La elección de un tipo de red que admita una retroalimentación interna, permite una representación más enriquecida de la dinámica del problema. Debido a su capacidad de memoria, las redes neuronales recurrentes han sido aplicadas exitosamente a problemas que involucran modelamiento y procesamiento de señales temporales (Ayaz *et al.*, 2003).

En este capítulo se presentan tanto los antecedentes teóricos necesarios para entender la dinámica del manto de nieve (Hidrología de Nieves), como el tipo de imágenes a utilizar y su origen (Percepción Remota), además de una descripción del modelo de red neuronal necesario para la generación del pronóstico de la escorrentía.

2.2. HIDROLOGÍA DE NIEVES


La nieve puede entenderse como un elemento del ciclo hidrológico (Figura 2.1), que se genera a partir de la precipitación de baja temperatura y que está gobernado por los procesos de acumulación y de derretimiento.



Figura 2.1. Ciclo del Agua.
Fuente: US Geological Survey.

Los procesos de acumulación y de deshielo ocurren continuamente en el tiempo, sin embargo, para entender la dinámica de estos procesos, con el fin de plantear una modelación, es necesario entender la escala espacio-temporal con que éstos ocurren (Semadeni-Davies, A. F. and Bengtsson, L., 2000). De acuerdo a la Figura 2.2 es posible plantear el fenómeno que se desea abordar y conocer la escala espacial y temporal asociada, que permitirá eventualmente seleccionar el tipo de información necesaria. Por ejemplo, el estudio de la escorrentía de deshielo está fuertemente relacionado a los períodos de acumulación y derretimiento de la nieve tanto a escala diaria como estacional. Además, estos procesos se desarrollan a una escala espacial a nivel de cuenca que va desde los cientos de metros a los cientos de kilómetros.

Los procesos de almacenamiento y derretimiento local de nieve se desarrollan a escalas diarias, por ejemplo, sobre el techo de una casa la nieve puede desaparecer en un par de días luego de la última nevada. Sobre una escala espacial mayor estos procesos cobran relevancia a escalas de tiempo estacionales, donde la acumulación es mayor a los derretimientos parciales en una estación y viceversa en la estación siguiente, lo que se traduce en la etapa de acumulación generada por las tormentas de precipitación sólida, y en la etapa de derretimiento producto de la elevación de las temperaturas y disminución de tormentas.



Los mecanismos que controlan el comportamiento del manto de nieve están fuertemente ligados a los procesos meteorológicos y por consiguiente a las variables atmosféricas existentes, siendo las más importantes la precipitación y temperatura que caracterizan la calidad y cantidad de las nevadas. Cuando no se produce nevada sobre el manto, éste experimenta una metamorfosis gobernada por el intercambio de calor en el manto y el medio ambiente, que puede ser abordada mediante un balance energético para lo cual es necesario estimar variables tales como temperatura, nubosidad, viento, humedad y precipitación líquida.

La distribución de la nieve a gran escala, como por ejemplo, a nivel de cuenca, está influenciada por los procesos de acumulación y derretimiento y condiciona la generación de la escorrentía. De esta manera, si se desea modelar la escorrentía de deshielo es necesario trabajar a una escala espacial que involucre la distribución de la nieve en la región aportante. La región aportante corresponderá tanto a la cuenca definida por el punto de salida donde se mide la escorrentía como a las zonas adyacentes que proporcionan agua mediante flujos sub-superficiales y afloramientos de aguas subterráneas.

Para entender los procesos involucrados en la caracterización del manto es necesario conocer algunas variables de estado como espesor, equivalente en agua, contenido de frío y calidad térmica (Tabla 2.1).

Tabla 2.1: Principales Variables de Estado de la Nieve

Espesor :	Altura o profundidad del manto de nieve.
Equivalente en Agua :	La equivalencia en lámina de agua del manto, que incluye el contenido en agua del manto y el agua líquida.
Contenido de Frío :	Calor o energía necesaria para llevar el manto a temperatura de fusión.
Calidad Térmica :	Medida que indica indirectamente la “edad” de la nieve, y está definida como el cociente entre la energía requerida para derretir todo el manto y el contenido de frío de éste.

Fuente: Valck, 2004.

A continuación se describe los principales procesos dinámicos de variabilidad del manto que son la acumulación y derretimiento de la nieve.

2.2.1. Almacenamiento

El almacenamiento de la nieve se produce por la acumulación de precipitación sólida sobre el manto. Al producirse una nevada, se produce una metamorfosis del manto en la que aumenta la cantidad de nieve acumulada, cambia la temperatura, se recongela el agua líquida y el manto se densifica por efecto del peso de la nueva capa. La acumulación de nieve no es continua y está precedida por derretimientos parciales a diferentes escalas de tiempo.

La acumulación de la nieve se entiende como un conjunto de capas de diferentes tipos de nieve (Nakawo, M. and Hayakawa, N., 1998), la cual está limitada por las características fisiográficas del terreno. Por tal motivo, en la determinación del área cubierta por nieve existirá un valor máximo que puede corresponder a un área parcial de la cuenca o al área total de esta.

La transferencia de energía ocurrida durante este fenómeno está liderada por un aumento en el contenido de frío de las capas, además de un aumento en el espesor y alteración en el equivalente en agua del manto.

2.2.2. Derretimiento


El derretimiento de la nieve provocado por la transferencia positiva de calor del medio sobre el manto es el principal factor que genera la escorrentía en cuencas cordilleranas. Esta transferencia de calor puede provenir de la radiación solar incidente, del suelo, de fuentes convectivas desde la atmósfera, de la conducción desde capas inferiores, de la precipitación líquida caída sobre el área cubierta de nieve o de una combinación de éstas. Los procesos de derretimiento ocurren casi en forma continua durante el año siendo el más importante el derretimiento paulatino en la época de deshielo (Semadeni-Davies and Bengtsson, 2000).

La precipitación líquida sobre la nieve puede generar una aceleración en los procesos de derretimiento pudiendo originar eventos de flujo extremos que se suman a los volúmenes provenientes de la precipitación.

2.2.3. Generación de la Escorrentía de Deshielo

El agua proveniente del derretimiento de nieve genera la escorrentía de deshielo, que corresponde al principal aporte de agua en períodos cálidos y sin tormentas en la zona cordillerana de Chile central. Estas

gotas de agua que alcanzan la superficie del suelo, poseen un carácter ambiguo en su origen, ya que pueden provenir de un almacenamiento en los intersticios del manto de nieve (Figura 2.3) o de la fusión propiamente tal en las regiones límites del manto. Las causas en la variabilidad del volumen de escorrentía en la época de deshielo son la variación del derretimiento generado sobre la superficie del manto, la heterogeneidad y variación temporal de las propiedades hidrológicas del manto, redirección del flujo por la topografía y la estratigrafía en el manto, y la no linealidad del flujo a través del medio poroso no saturado (Harrington and Bales, 1998).



Sobre el suelo, la conductividad hidráulica estará sujeta no sólo a las características del medio poroso, sino también a la humedad. Elementos como la capacidad de infiltración dependerán en gran parte de estas variables, siendo mayor si el suelo se encuentra seco a una temperatura por sobre los 0 °C.

2.3. PERCEPCIÓN REMOTA

La estimación del área cubierta de nieve es un elemento integral de la modelación hidrológica para las cuencas de montaña. Su importancia práctica radica en la simulación y el cálculo a las contribuciones del derretimiento de la nieve hacia la escorrentía.

Las mediciones de la cobertura de nieve son tediosas y dificultosas. Los métodos convencionales tienen limitaciones en el monitoreo del área cubierta de nieve en zonas de gran altitud como por ejemplo, en cuencas glaciares, debido a lo accidentado del terreno y a las severas condiciones climáticas. En esta perspectiva, las imágenes satelitales unidas al análisis de percepción remota constituyen una poderosa herramienta para determinar el área cubierta de nieve a intervalos regulares de tiempo (Vikhamar and Solberg, 2003; Gupta *et al.*, 2005)

Los métodos de percepción remota, también llamados de teledetección, son necesarios para proveer información sobre la variabilidad espacial y temporal de las propiedades de la nieve con los que se pueden evaluar y validar los modelos de clima e hidrología (Shi and Dozier, 1997). En la parte visible del espectro, la nieve es más brillante que otras clases de cubierta, es por esto que el mapeo de la nieve es simple cuando la iluminación es suficiente y la cubierta de nubes es nula. En el infrarrojo cercano e infrarrojo de onda corta se puede estimar el tamaño del grano de nieve y discriminar entre nubes y nieve (Dozier, 1989).

2.3.1. Elementos de Percepción Remota

La percepción remota puede definirse como una aplicación a través de la cual se puede obtener información de los objetos o fenómenos sin estar en contacto físico con ellos. Posteriormente, dicha información debe ser analizada e interpretada para obtener así los datos requeridos para un estudio en particular.

La información es obtenida a distancia mediante instrumentos llamados sensores remotos, que miden variaciones espectrales, espaciales y/o temporales, de los objetos o fenómenos de interés. Las características de los objetos o fenómenos a que se hace referencia están en los campos de fuerza, ondas acústicas y campos electromagnéticos, siendo este último el que ha sido mayormente desarrollado. Uno de los métodos más convenientes y prácticos de clasificar la energía electromagnética es mediante la división del espectro en bandas elegidas según la longitud de onda.

Para la aplicación de técnicas de percepción remota se deben seguir las siguientes etapas (Muñoz, 1986):

- 1ª Etapa: Distinguir una necesidad de información acerca de un objeto o fenómeno.
-
- 2ª Etapa: Seleccionar el o los sensores remotos más adecuados, en términos de resolución espacial, periodicidad de observación y banda espectral.
-
- 3ª Etapa: Procesar la información a partir de las imágenes seleccionadas.
-
- 4ª Etapa: Analizar e interpretar la información ya procesada.
-
- 5ª Etapa: Validar la información, mediante comprobaciones en terreno o trabajos anteriores.
-
- 6ª Etapa: Evaluar los resultados.

De estas etapas, las más importantes corresponden a la segunda y tercera puesto que son la base de la metodología de la teledetección. La magnitud del problema como entrada en estas etapas, será básica para la determinación de las dimensiones de las imágenes a utilizar.

Si el problema a abordar es de carácter dinámico en el tiempo, será necesario seleccionar aquellos sensores de alta o mediana periodicidad (1 a 30 días) para tener un registro continuo en el tiempo, o sino, se tendrá que evaluar el empleo de diferentes sensores para su uso conjunto. En otro sentido, la magnitud espacial del objeto a analizar definirá la escala mínima a la que podría ser detectado en la imagen y por lo tanto explicará la resolución espacial susceptible de utilizar.

2.3.2. Uso de Imágenes Satelitales en la Modelación de la Escorrentía de Deshielo

La información satelital permite realizar una evaluación enriquecida al problema de la modelación de la escorrentía porque:

- Puede hacer distinción acerca de la variabilidad de factores que afectan de forma directa o indirecta a la variable modelada.
- Está disponible a espacios regulares de tiempo lo que permite abordar un problema continuo de forma discreta en el tiempo.
- Permite realizar evaluaciones de bajo costo que serán validadas in-situ o a través la utilización de un amplio paquete de referencias.

De las alternativas evaluadas para este estudio, las imágenes tipo MODIS fueron las que cumplían con los requisitos de escala en sus diferentes tipos, los que se especifican a continuación.

2.3.3. Imágenes Satelitales MODIS

El 18 de Diciembre de 1999 fue lanzada la nave espacial Terra Earth Observing System (EOS), con un complemento de 5 instrumentos, uno de los cuales era el Moderate Resolution Imaging Spectroradiometer (MODIS), el cual sería capaz de estudiar las características geofísicas a nivel global sobre una base diaria, incluyendo el mapeo de la cubierta de nieve (Hall *et al.*, 1995; Hall *et al.*, 2002). Actualmente, los productos son transferidos al National Snow and Ice Data Center (NSIDC), donde son archivados y distribuidos de forma gratuita por medio de EOS Data Gateway (EDG).

Estas imágenes proveen una estimación del espectro reflejado de la superficie terrestre mediante sus 36 bandas discretas (Tabla 2.2).

Tabla 2.2: Bandas de MODIS y Rango Espectral

Banda #	Rango Espectral [μm]	Banda #	Rango Espectral [μm]
1	0.620-0.670	19	0.915-0.965
2	0.841-0.876	20	3.660-3.840
3	0.459-0.479	21	3.930-3.990
4	0.545-0.565	22	3.930-3.990
5	1.230-1.250	23	4.020-4.080
6	1.628-1.652	24	4.430-4.450
7	2.105-2.155	25	4.480-4.550
8	0.405-0.420	26	1.360-1.390
9	0.438-0.448	27	6.540-6.900
10	0.483-0.493	28	7.180-7.480
11	0.526-0.536	29	8.400-8.700
12	0.546-0.556	30	9.580-9.880
13	0.662-0.672	31	10.78-11.28
14	0.673-0.683	32	11.77-12.27
15	0.743-0.753	33	13.19-13.49
16	0.862-0.877	34	13.49-13.79
17	0.890-0.920	35	13.79-14.09
18	0.931-0.941	36	14.09-14.39

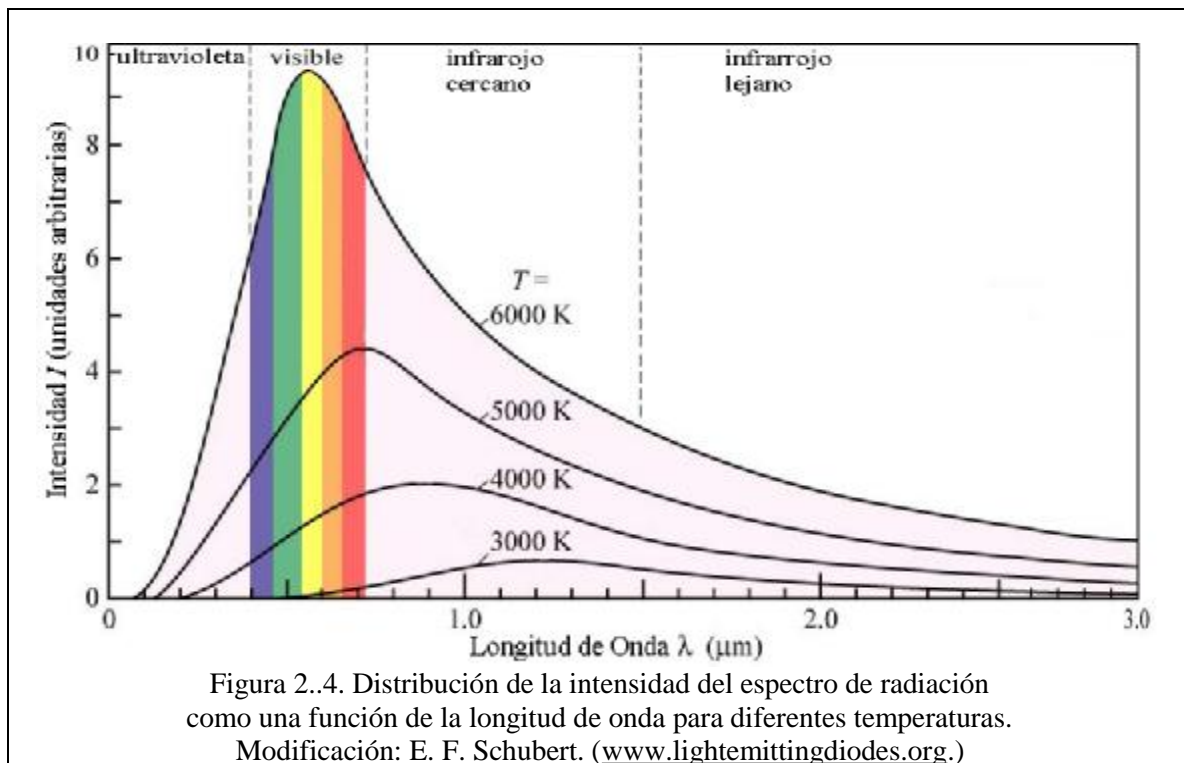
Fuente: Hall *et al.*, 1995.

La resolución espacial para sus diferentes bandas es de 250, 500 y 1000 m. Las bandas del espectro cubren una parte del espectro electromagnético completo, entre 0,4 y 14,0 μm , por lo cual incluyen la parte visible e infrarrojo termal del espectro (Figura 2.4).

Con la finalidad de realizar múltiples investigaciones a los cambios de la superficie global terrestre, entre las que se cuentan la cobertura vegetal, nieve y hielo como las más importantes, se desarrollaron diferentes algoritmos para obtener el máximo de información. Por ejemplo Hall *et al.*, (1995) utilizó el algoritmo SNOMAP (Riggs *et al.*, 1994) para el mapeo de la nieve (MODIS snow-mapping), el cual permite determinar el área cubierta de nieve sobre la región $\pm 45^\circ$ de la imagen. Otros algoritmos de corrección atmosférica se preocupan de corregir efectos por dispersión y absorción asociados a aerosoles y gases, acoplamiento atmosférico y contaminación proveniente de las nubes tipo cirrus (Vermote, 1999).

Hoy en día están disponibles una amplia gama de productos asociados al campo de la geofísica derivados de MODIS. Productos a nivel global de la cobertura de nieve, MODIS Snow-Cover (MOD10) están disponibles desde el 13 de Septiembre del año 2000, a nivel diario y cada 8 días. Otros productos

con corrección atmosférica como las MODIS Surface Reflectance (MOD09), también a nivel diario y cada 8 días están disponibles desde el 26 de Febrero del año 2000.



Para la correcta selección de las imágenes a utilizar es necesario entender los algoritmos básicos que existen detrás de estos derivados. Dichos algoritmos han sido desarrollados y validados en otras regiones donde las condiciones fisiográficas son muy diferentes a las existentes en Chile; esto sugiere que la selección de las imágenes incluya no sólo la evaluación de los algoritmos sino también la apreciación de las hipótesis existentes detrás de estos algoritmos. Uno de los principales algoritmos es el que permite distinguir aquellas regiones donde existe cobertura de nieve.

2.3.4. Detección de elementos con/sin Nieve

En la parte visible del espectro, tanto la nieve como las nubes son de color blanco y brillantes, lo que es responsable de la confusión entre ellas, y se traduce en un gran problema en la estimación de la cubierta de nieve (e.g. Hall *et al.*, 1995). Otra importante consideración la constituyen las sombras de las montañas, la que depende principalmente de la ubicación del sensor respecto a la posición del sol. En tales casos, es muy dificultoso discriminar entre cobertura de nieve bajo sombras de montaña, de áreas desprovistas de nieve.

Algunas técnicas de teledetección desarrolladas permiten solucionar estos problemas, como es el Índice Normalizado de Diferenciación de Nieve o en inglés: *Normalized Difference Snow Index* (NDSI). La nieve es caracterizada por una alta reflexión en el rango visible (0.5-0.7 μm) y una fuerte absorción en el infrarrojo de onda corta (SWIR) (1.0-3.5 μm). En contraste, las nubes sólo poseen una alta reflexión cuasi uniforme en el rango visible (Gupta *et al.*, 2005). De esta manera el filtro NDSI permite distinguir nieve de otras cubiertas, siendo la más problemática la cobertura nubosa. Este filtro está basado en el concepto del Índice de Diferenciación Vegetal Normalizado (NDVI) ampliamente usado en la discriminación de cobertura vegetal (Dozier, 1989; Hall *et al.*, 1995).

El NDSI está definido como la diferencia de reflexión observada en una banda visible, usualmente la banda verde que en MODIS corresponde a la Banda 4 (0.545-0.565 μm), y la banda infrarroja de onda

corta, que en MODIS corresponde a la Banda 6 (1.628-1.625 μm), dividido por la suma de las dos reflexiones.

$$\text{NDSI} = \frac{(\text{Band4} - \text{Band6})}{(\text{Band4} + \text{Band6})} \quad [2.1]$$

Como resultado de la operación matemática, el NDSI resultante en cada píxel puede tomar valores entre -1 y 1. Si bien el NDSI está diseñado para discriminar cobertura nival de otras coberturas, la elección del valor límite de discriminación entre nieve y no-nieve (umbral), representa un problema singular, ya que depende de múltiples factores tales como ángulo de elevación, condiciones atmosféricas, estación anual (Choi, 2004) y sensor satelital. Las condiciones estacionales que reducen la efectividad del NDSI tienen relación con que la absorción de la nieve en el infrarrojo cercano se incrementa con el tamaño del grano de nieve (Dozier, 1989) lo que agrega sutileza en la selección del valor umbral del NDSI. La selección del valor umbral de NDSI para distinguir entre nieve/no-nieve es una tarea delicada en la que ligeros cambios pueden generar una sobrestimación o subestimación del área cubierta de nieve (Gupta *et al.*, 2005). El área cubierta de nieve queda definida por el número de píxeles que responden a un valor mayor o igual al umbral definido, multiplicado por el área de cada píxel.

2.3.5. Diferenciación de elementos con Nieve


Los análisis de espectrometría permiten examinar algunas propiedades físicas de la nieve, tales como tamaño de grano mediante el ancho de banda del albedo (Wiscombe and Warren, 1980). Cambios en el tamaño del grano son un importante indicador de los procesos termodinámicos involucrados en el manto y permiten identificar algunas características superficiales del manto tales como: áreas en derretimiento, dunas, y zonas de nieve recongelada (Nolin and Dozier, 2000). La región del espectro más sensible a los cambios en el tamaño del grano corresponde al rango infrarrojo cercano (NIR: 1,0-1,5 μm), sin embargo, factores como la geometría solar pueden alterar la longitud de onda medida en este rango (Painter and Dozier, 2004). En general, la reflexión de la nieve decrece con el aumento del tamaño de los granos y con la edad de la nieve (Hall *et al.*, 1992).

El radio efectivo de un grano de nieve generalmente es de alrededor de 50 μm para nieve fresca, en tanto que para nieve de una mayor edad este radio es de 1000 μm (1 mm), nieve húmeda o conjunto de granos (Nolin and Dozier, 2000) (Figura 2.5).

Esto último se debe a que durante un período mayor de tiempo, puede ocurrir el derretimiento en el agua líquida que cause la unión entre los granos con un resultado visual que corresponde a granos más grandes. Si la nieve húmeda se recongela, la reflexión de esta última no sufre mayores variaciones, lo que trae consigo una ambigüedad entre la nieve húmeda y el hielo con las mismas propiedades ópticas. Esta particular relación trae como consecuencia la confusión entre el hielo formado por el recongelamiento de la nieve y el hielo glaciar (Gupta *et al.*, 2005).

La radiación puede penetrar el manto hasta varios decímetros en profundidad. Por ello la reflexión o albedo podría depender también de la estratificación del manto. Es así como se aprecia una fuerte disminución del albedo aparente en mantos de poca altura o espesor, en que la radiación logra penetrar hacia el manto (Stowhas, 2008).

Por sus propiedades físicas, el borde de la nieve húmeda exhibe un sistemático movimiento hacia las cumbres más altas a medida que avanza la época de deshielo, fenómeno que tiene directa relación con el contenido de frío de la nieve. Este particular patrón en la distribución espacial, explica la disminución en la reflexión en el infrarrojo cercano producto de la humedad que se exhibe sobre la superficie de la nieve en derretimiento (Gupta *et al.*, 2005).

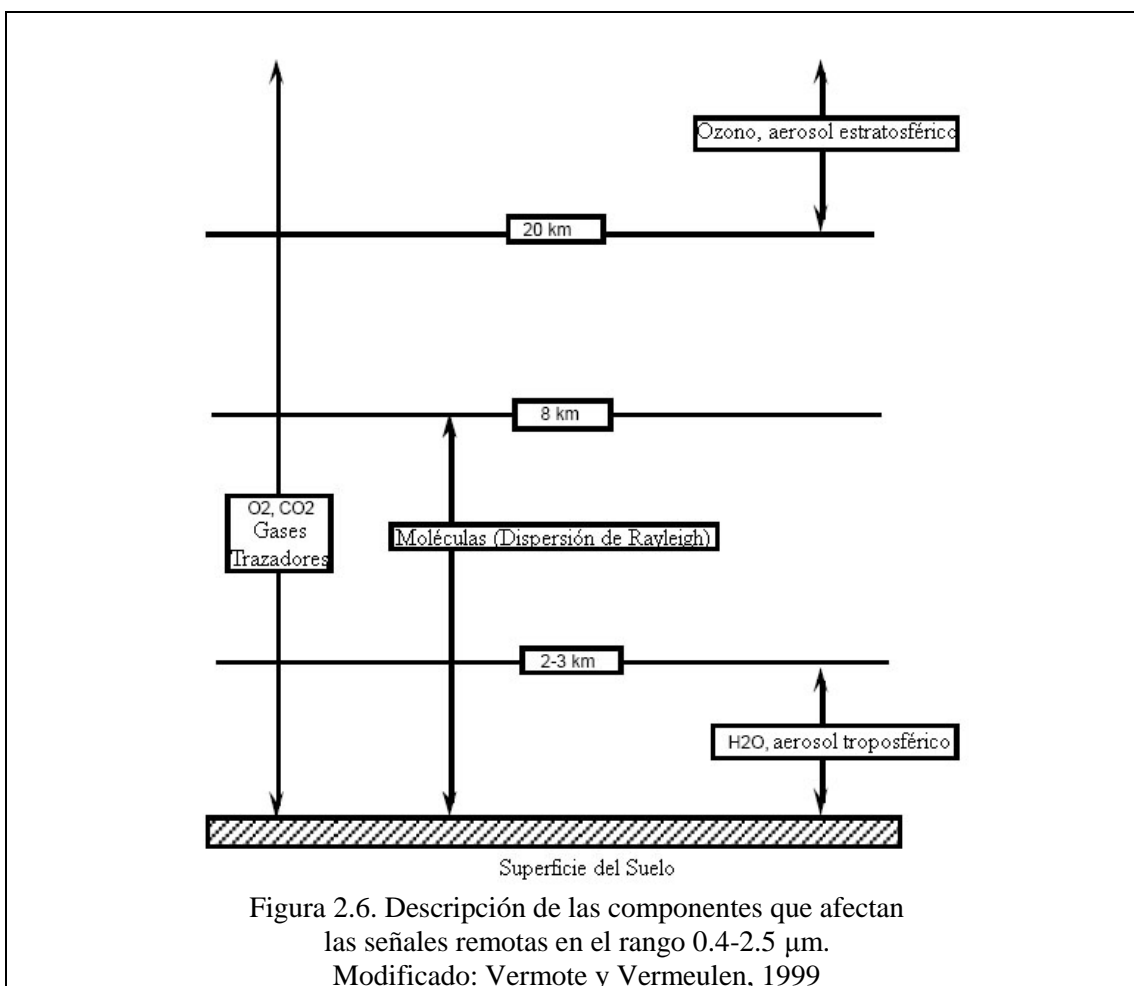


2.3.6. MODIS Surface Reflectance (MOD09)

El uso de imágenes MODIS para el estudio de las diferentes coberturas sobre la tierra requiere que la señal obtenida desde la parte superior de la atmósfera (Figura 2.6) sea convertida a una reflexión a nivel del suelo (Vermote and Vermeulen, 1999). El proceso necesario para esta conversión es llamado corrección atmosférica.

Este tratamiento consiste en la aplicación de variados algoritmos y códigos de procesamiento asociados sobre imágenes MODIS de nivel de luminosidad 1B, el cual pertenece a un rango específico de luz percibida. Los productos atmosféricos de MODIS a utilizar son: (i) MOD04: aerosoles, (ii) MOD05: vapor de agua, (iii) MOD07: ozono, (iv) MOD37: máscara nubosa. La corrección atmosférica requiere que la señal obtenida provenga desde la cima de la atmósfera y consiste en la modelación correctiva de la dispersión y absorción atmosférica. Para mejorar la precisión de esta corrección se requiere una corrección adicional sobre la función de dispersión del punto (PSF - Point Spread Function) en la atmósfera (para bandas de alta resolución espacial) y de la corrección de la radiación atmosférica acoplada a la función de distribución de reflexión bidireccional (BRDF - Bidirectional Reflectance Distribution Function) determinada a partir de correcciones sobre imágenes AVHRR (Advanced Very High Resolution Radiometer) y Landsat TM (Thematic Mapper), (Vermote and Vermeulen, 1999).

Las imágenes MOD09 son una de las principales entradas utilizadas en la generación de algunos productos tales como: Índices de Vegetación (Vegetation Indices), Función de Distribución de Reflexión Bidireccional (BRDF), Cubiertas de la Tierra (Land Cover), Cubierta de Nieve (Snow Cover), Anomalías Termales (Thermal Anomalies), e Índice de Área de Hojas (LAI) y Fracción de Radiación Fotosintética Activa (FPAR) absorbida por la vegetación (<http://modis-sr.ltdri.org>).



2.3.7. MODIS Snow-Cover (MOD10)

El algoritmo MODIS Snow-Mapping que se utiliza para generar el derivado MODIS Snow-Cover discrimina la cubierta de nieve mediante la utilización del NDSI, unido a determinados criterios que son válidos en regiones donde la cobertura vegetal es importante. El NDSI filtra la mayor parte de las nubes, con la excepción de las altas nubes, las que contienen hielo que puede ser a menudo considerado erróneamente como nieve (Hall *et al.*, 2002). Un píxel ubicado en una región forestada de baja densidad será mapeada como nieve si el NDSI es $\geq 0,4$ y la reflectancia en la Banda 2 (0.841-0.876 μm) es mayor a 11%; sin embargo, si la Banda 4 (0.545-0.565 μm) es menor al 10%, entonces el píxel no será mapeado como nieve. Esto es requerido porque reflexiones muy bajas causan que el denominador en el NDSI sean bastante pequeño y sólo pequeños incrementos en el rango visible sean necesarios para que el valor del NDSI sea lo suficientemente alto para clasificar a un píxel, erróneamente, como nieve (Hall *et al.*, 2002). Sobre regiones forestadas existe un cambio fundamental en la variación de la cubierta de nieve, puesto que la reflectancia en el rango visible, a menudo aumentará con respecto a la reflexión del infrarrojo cercano generando una sobrestimación del área cubierta de nieve.

La introducción de una máscara termal (e.g., Romanov *et al.*, 2000) el 3 de Octubre del año 2001 mejoró el algoritmo MODIS Snow-Mapping, eliminando falsa cubierta de nieve que fue encontrada en algunas partes del planeta en los primeros mapas de cubierta de nieve MODIS. Esta técnica considera las bandas 31 (10,78 – 11,28 μm) y 32 (11,77 – 12,27 μm) para estimar la temperatura a nivel del suelo. Si la temperatura de un píxel es mayor a 277° K, entonces el píxel no será mapeado como nieve.

Debido a que la cubierta nubosa se extiende por un período mayor a 24 horas en algunas regiones, a

menudo se excluye la adquisición de la cubierta nival usando los sensores visibles e infrarrojo cercano. Una solución a este problema es mediante la composición del mapeo diario en un producto de 8 días. Estos productos también existen para las imágenes MOD09 y la escala espacial para estos productos es de 15 segundos de arco ($\approx 500\text{m}$).

2.3.8. Validación General de las Imágenes MODIS

La validación de la información es básica para asegurar su uso posterior. En este sentido, las imágenes satelitales requieren un asiduo estudio en el que se requiere verificar la información recolectada mediante su comparación con la información real medida en terreno. Esta labor puede ser realizada mediante inspección visual o mediante la utilización de sensores que discriminen los espectros de los diferentes elementos existentes en una determinada región, la cual es comparada más tarde con la información visualizada en la imagen. Si bien, en estricto rigor, sería necesario validar cada píxel de una imagen, se acepta que sólo algunos puntos sean muestreados y chequeados con la imagen. Existen diferentes trabajos que han validado las imágenes MODIS en distintas regiones del planeta, sin embargo, siempre será necesario su validación rigurosa en la región de estudio. A continuación se indicarán los estudios de mayor relevancia relacionados a la validación de las imágenes MODIS. La validación puntual de las imágenes a utilizar se describe en el Capítulo IV.

La validación de las imágenes MODIS se remonta al año 1995 con el trabajo de Hall, Riggs y Salomonson, en el que se evaluó la aplicación del algoritmo SNOMAP en imágenes MODIS para la discriminación del área cubierta de nieve en Montana (EEUU). En el año 2002, los mismos autores validaron las imágenes MOD10 sobre toda la región de los EEUU.

La validación de las imágenes MOD09 se remonta al año 2002 con el estudio realizado por Vermote *et al.*, donde se validó la corrección atmosférica mediante la comparación de información AERONET y la información de las imágenes mediante comparación con imágenes Landsat ETM+ en diferentes puntos de la tierra (<http://modis-sr.ltdri.org>).

En el año 2004, V. Salomonson e I. Appel validaron el uso del NDSI sobre imágenes MODIS para distinguir la cubierta de nieve en diferentes regiones de la Tierra entre las que se cuentan Alaska, Siberia (Russia), Labrador (Canadá), y la cordillera de los Andes (Chile/Argentina). En el mismo año, Maurer *et al.*, evaluaron estas imágenes en las cuencas de los ríos Missouri y Columbia (EEUU) mediante las mediciones de dos redes de monitoreo, NOAA Cooperative Observer y US Natural Resources Conservation Service SNOpack TELEmetry (SNOTEL). Klein y Barnett, también en el año 2003, validaron las imágenes MODIS snow-cover a escala diaria utilizando la red SNOTEL en la cuenca del río Río Grande y al norte de Nuevo México (EEUU). En el año 2004, Simic *et al.*, validaron las imágenes MOD10 a escala diaria en Canadá mediante mediciones in situ.


En el año 2006, Tekeli *et al.*, evaluaron el albedo de las imágenes MODIS Snow-Albedo a escala diaria, mediante mediciones in situ en la cuenca de Karasu (Turkia). En el mismo año, Hall y Riggs evaluaron la aproximación de la cubierta de nieve a partir de las imágenes MODIS Snow Products en todo el mundo. Stroeve *et al.*, también en el año 2006, evaluaron el albedo medido a partir de imágenes MODIS Snow-Albedo a escala diaria, mediante mediciones in situ en la región de Groenlandia.

En general, todos los trabajos muestran un grado de invalidez en sus resultados cuando se trata de comparar la información que se desea validar. Diferentes variables condicionan los resultados, en mayor o menor magnitud y para diferentes imágenes, regiones y períodos, lo que hace más incierto la búsqueda de una jerarquía necesaria para estas variables cuando se emplea un grupo de imágenes del mismo tipo.

2.4. REDES NEURONALES


Un típico esquema del cuerpo de una neurona biológica es mostrado en la Figura 2.7. Cualitativamente, la neurona realiza una integración espacial y temporal de señales que son transmitidas a través de las dendritas. Si la potencia eléctrica es suficiente, ésta es conservada en el cuerpo de la célula o soma y una acción potencial es generada y propagada a lo largo del axón. El axón trasporta esta señal a otras neuronas mediante la sinapsis la cual representa el punto de modulación y amplificación de la señal.

El análisis neuronal matemático ha evolucionado desde consideraciones anatómicas simples a interacciones moleculares individuales; los modelos actuales incorporan elementos de la química cinemática. Desde una perspectiva computacional en el área de la neurociencia, se desea una modelación matemática que permita reconstruir los procesos esenciales de la señal neuronal, sin embargo, todavía es muy complejo abordar las interacciones electro-químicas que se generan en el axón.



2.4.1. Neurona Artificial

En 1943, McCulloch y Pitts plantearon uno de los modelos matemáticos más simples para una neurona (Figura 2.8).



La salida de la neurona es simplificada por una función no lineal donde la salida corresponde a la suma ponderada de las entradas:

$$s = \sum_{i=1}^N w_i x_i + w_b \quad [2.2]$$

$$y = f(s) \quad [2.3]$$

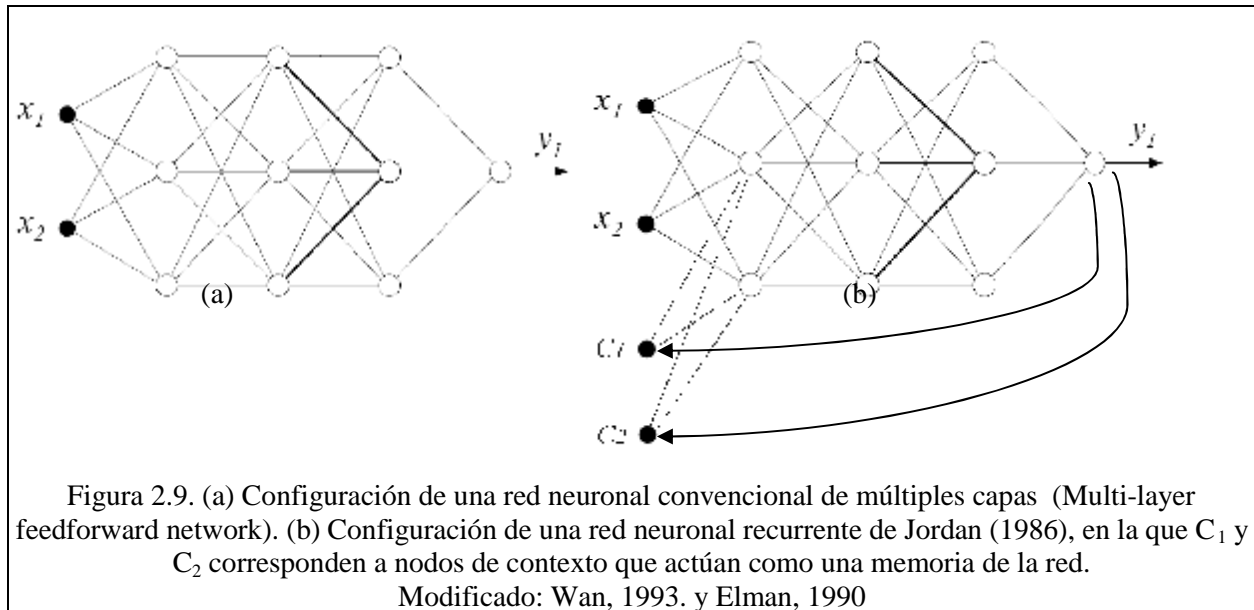
Donde x_i son las entradas a la neurona, w_i son los pesos sinápticos, y w_b representa el sesgo de la red. La función f corresponde a la función de activación y es, en general, de carácter no lineal.

Los primeros modelos utilizaron un valor umbral o la función signo como función de activación y se ha evolucionado hacia funciones más complejas como la función sigmoide, usualmente evaluada por la función diferenciable $y = \tanh(s)$ mostrada en la Figura 2.8.b. El modelo de una neurona es conocido en la literatura como el modelo Perceptron o Adaline.

2.4.2. Redes Neuronales de Múltiples Capas

Las Redes Neuronales Artificiales (RNA) consisten en la simple agrupación de neuronas artificiales. Este agrupamiento se realiza creando capas de neuronas, las cuales a su vez se conectan entre sí, dando forma a las redes de múltiples capas o multi-capas (Figura 2.9). La alimentación o entrada de una capa podrá provenir de la información inicial o desde otra capa. Las configuraciones de alimentación también pueden variar dependiendo del modelo neuronal que se desee implementar, siendo las más comunes:

- *las Redes Prealimentadas (feedforward connections)*, en la que la salida de una neurona actúa como la entrada de la neurona en la capa siguiente;
- *las Redes Recurrentes (feedback or recurrent connections)*, en la que la entrada a una neurona proviene de información que posee un retardo temporal.



La capacidad de aprendizaje de una red neuronal está determinada por su arquitectura y por el método o algoritmo escogido para entrenar. El método de entrenamiento normalmente se basa en uno de estos tres esquemas:

- *Aprendizaje No Supervisado*, las neuronas ocultas deben encontrar una manera de organizarse sin información del error o de un instructor externo que conozca la salida deseada. En este esquema, ninguna muestra de la salida se le proporciona a la red de modo que ésta no

pueda medir su rendimiento frente a un vector de entradas dado. La red debe encontrar la información relevante en los vectores de entrada redundantes.

- *Aprendizaje Supervisado*, la red es alimentada con información acerca de cómo está resolviendo el problema. En este caso, la red requiere un instructor, el cual puede ser un conjunto de datos de entrenamiento, formado por valores de entrada y salida deseada, o bien, un observador externo que gradúe el rendimiento de la red.
- *Aprendizaje Reforzado*, se utiliza cuando no se dispone de un conjunto de datos de entrenamiento ni de un observador externo que conozca la salida deseada. Generalmente, la única información disponible es una evaluación escalar que indica el desempeño de la red neuronal con un retardo, ya que la evaluación es obtenida a partir de las salidas de la red en el pasado. La red se ajusta reforzándola con una predicción de esta evaluación, la cual se utiliza además para ajustar la misma predicción.

En el presente trabajo se utilizaron las redes neuronales del tipo recurrentes y se aplicó el aprendizaje supervisado como método de aprendizaje.

2.4.3. Redes Neuronales Recurrentes

Las redes convencionales prealimentadas pueden ajustarse a la dinámica del problema de predicción mediante el uso de valores pasados en las entradas a la red, y también en las salidas de las neuronas ocultas como un conjunto aumentado de entradas.


Las redes neuronales recurrentes poseen básicamente la misma estructura de capas de las redes convencionales prealimentadas. La principal diferencia con estas últimas es que los pesos sinápticos de las neuronas en las redes recurrentes son modelados como un filtro autorregresivo (Connor *et al.*, 1994), y poseen retroalimentaciones internas de los valores pasados de sus neuronas, tanto de las capas ocultas como de la capa de salida.

2.4.4. Redes Neuronales Recurrentes Dinámicas

Las redes neuronales recurrente dinámicas (DRNN – Dynamical Recurrent Neural Network) son una clase de redes. En la terminología de teoría de señales, la interacción de las neuronas es tratada como filtros de Respuesta Finita al Impulso (FIR – Finite Impulse Response). Los parámetros de los filtros son ajustados continuamente para seleccionar aquellos aspectos de la secuencia de entrada que son relevantes para hacer asociaciones temporales. Con esto se espera que tal dinámica interna habilite a la red para encontrar una representación apropiada a su estado interno que le permita capturar el comportamiento de la serie de tiempo (Aussem *et al.*, 1995).

A pesar del potencial y la capacidad de las DRNNs, el principal problema que poseen es la dificultad de entrenamiento sumado a la complejidad y lentitud en la convergencia de los algoritmos de entrenamiento existentes.

El algoritmo de entrenamiento más conocido es el algoritmo Backpropagation o retropropagación del error. Para las redes neuronales recurrentes existe además el algoritmo Temporal Backpropagation, el cual se basa en el método del gradiente y busca minimizar una función de error definida en el espacio formado por los pesos de la red (Wan, 1993). Los algoritmos basados en el método del gradiente presentan la gran desventaja de que pueden caer en mínimos locales durante el entrenamiento (Figura 2.10). A continuación se describe con mayor detalle las ecuaciones involucradas en el algoritmo backpropagation.



2.4.5. Algoritmo Backpropagation y Filtro FIR

A partir del aprendizaje supervisado, la respuesta de la red puede ser comparada con la *respuesta deseada* y , definida por la Ecuación 2.4. Para un *conjunto de entrada* x , la diferencia entre la salida deseada y la respuesta del modelo corresponde al *error* e .

$$y = \sum_{i=0}^N w_i x_i = w^T x \quad [2.4]$$

$$e = d - y \quad [2.5]$$

El *error cuadrático* J , del entrenamiento está dado por la Ecuación 2.6.

$$J = \sum_{p=1}^P e_p^T e_p \quad [2.6]$$

El objetivo del entrenamiento es determinar el conjunto de *pesos* w , que minimizan la función de costo J , sujeto a la restricción de la topología de la red. A partir de esta formulación, el entrenamiento de la red se transforma en un problema de optimización, donde el objetivo es actualizar los pesos de acuerdo al gradiente decreciente que determina el decremento más rápido del error.

$$\Delta w = -\mu \nabla = -\mu \frac{\partial J}{\partial w} = -\mu \sum_p \frac{\partial e_p^T e_p}{\partial w} \quad [2.7]$$

Donde μ representa la tasa de aprendizaje y ∇ representa al gradiente del error cuadrático.

Un *estimador insesgado para el gradiente del error cuadrático* $\hat{\nabla}$ corresponde a la expresión definida en la Ecuación 2.8.

$$\hat{\nabla} = \frac{\partial e^T e}{\partial w} = \frac{\partial e^2}{\partial w} = 2e \frac{\partial e}{\partial w} \quad [2.8]$$

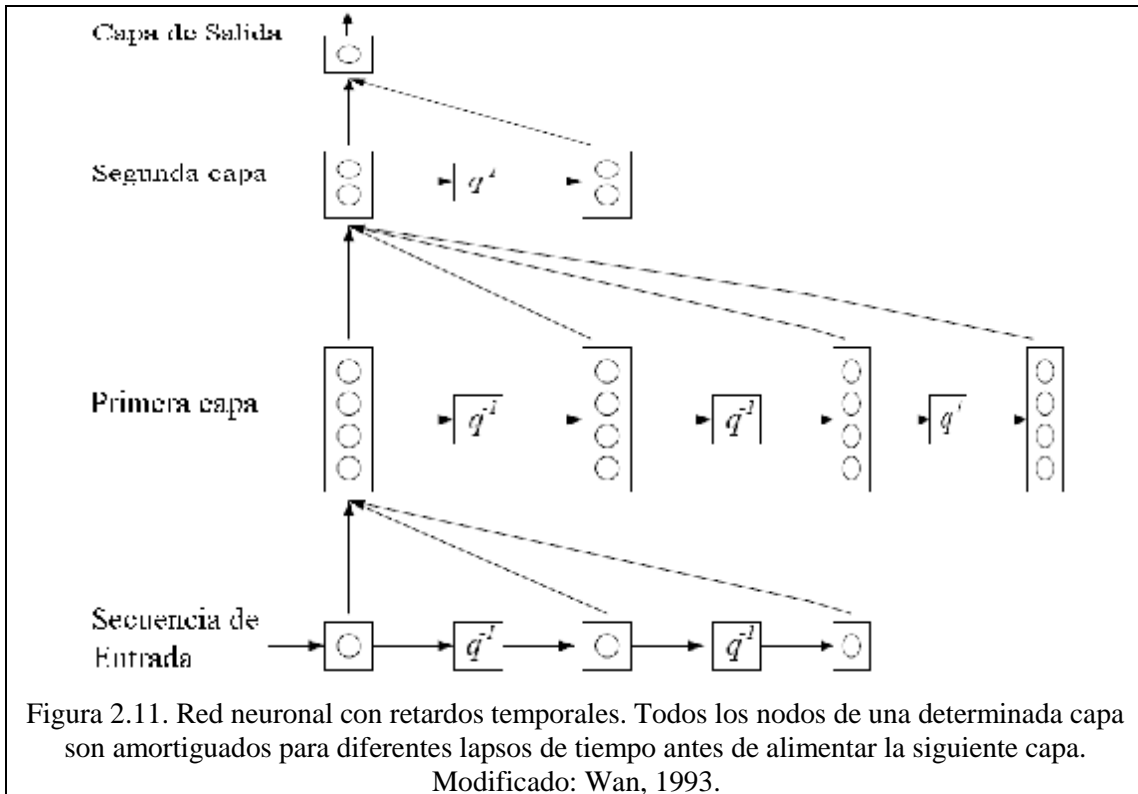
$$\hat{e} \quad \Delta w = 2\mu e x_i \quad [2.9]$$

La Ecuación 2.9 representa el algoritmo del error cuadrático medio mínimo, y permite el ajuste recursivo del conjunto de pesos w .

Una de las primera aplicaciones del filtro FIR fue desarrollado por Bernard Widrow (1960). Este consistió alimentar a la neurona desde un retardo de información, es decir, $y(k) = \sum_i^N w_i x(k-i)$, donde k corresponde a un tiempo discreto.

Una configuración equivalente a la redes FIR son las redes con retardo temporal (TDNN – Time Delay Neural Network) que se muestra en la Figura 2.11 y permite comprender la conexión entre neuronas y retardos asociados. La secuencia de entrada a la primera capa posee un retardo indicado mediante la expresión “ q^{-1} ”, luego, en la segunda capa, la información de la primera capa estará sujeta a otros

restardos y así sucesivamente hasta la capa de salida.



2.4.6. Predicción con un Modelo Neuronal Artificial

Hay dos aspectos fundamentales que dificultan el análisis de una red neuronal recurrente. El primero es que es usual suponer que tales redes se compondrán de una cantidad no despreciable de neuronas, que estarán en directa relación con el número de pesos o parámetros del modelo. El segundo aspecto es que cada neurona contribuye con una función no lineal a los cálculos de la red, lo cual genera un sistema altamente no lineal que requiere de métodos complejos para obtener resultados a través de su comportamiento colectivo.

En otro aspecto, las redes neuronales artificiales tienen la gran desventaja de que la búsqueda de la arquitectura apropiada para resolver el problema consume mucho tiempo, ya que dicha búsqueda se realiza básicamente mediante un proceso de tanteo, en el cual se intenta explorar la mayor cantidad de arquitecturas posibles. Además, el proceso de aprendizaje de la red puede tomar un tiempo considerable dependiendo de la cantidad de datos de entrenamiento.

La búsqueda del modelo neuronal apropiado para resolver el problema de predicción, o cualquier otro problema en general, requiere una metodología similar a la requerida por modelos estadísticos. En este caso, los pasos de la metodología para realizar la predicción de una serie de tiempo mediante redes neuronales son:

- preprocesamiento de datos de entrada a la red,
- definición de la arquitectura de la red,
- entrenamiento de la red utilizando un conjunto de entrenamiento y otro de validación,
- evaluación del modelo seleccionado usando un nuevo conjunto de prueba,
- predicción de la serie de tiempo.

La elección de la red neuronal se realiza evaluando el desempeño de todas las arquitecturas exploradas para escoger la arquitectura que presenta el mejor desempeño frente a un problema dado.

Generalmente, la evaluación de las redes neuronales se realiza dependiendo del tipo de problema que se desea resolver. En el caso de la predicción de series de tiempo suele utilizarse el error cuadrático medio, el error cuadrático medio normalizado o bien el coeficiente de determinación. El parámetro más importante para evaluar la precisión de la predicción es el coeficiente de determinación (Drossu and Obradovic, 1996). Estos parámetros de evaluación se aplican tanto al conjunto de entrenamiento como al de validación. La red recurrente más apropiada para predecir la serie de tiempo se escoge como aquella que presenta el mejor desempeño de predicción del conjunto de validación. Es decir, se escoge la red que presenta un coeficiente de determinación con el valor más cercano a 1 para el conjunto de validación.

Una vez que se escoge el mejor modelo neuronal, se evalúa el desempeño de la red sobre un tercer conjunto de datos independientes, el conjunto de prueba. Esto se hace para verificar la capacidad de generalización de la red neuronal.

2.5. EVALUACIÓN ESTADÍSTICA DE LOS RESULTADOS DEL MODELO

Para el análisis posterior de la respuesta del modelo es necesario recordar algunos conceptos estadísticos básicos y algunos indicadores para el diagnóstico del modelo.

2.5.1. Conceptos Estadísticos Básicos

La *esperanza* $E(x)$ representa una medida de la “tendencia central” de la variable. Ésta puede ser estimada por el promedio de la serie finita x_t de N muestras en el tiempo, definida por la Ecuación 2.10.

$$E(x) \approx \bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad [2.10]$$

La *varianza de una muestra* s_x^2 es usada para medir la variación de los datos y puede ser estimada por la Ecuación 2.11.

$$s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 \quad [2.11]$$

La *desviación estándar de una muestra* s_x puede ser estimada mediante la Ecuación 2.12.

$$s_x = \sqrt{s_x^2} = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad [2.12]$$

El *coeficiente de correlación lineal* r es una medida de la relación entre 2 o más variables y ofrece una medida cuantitativa de la fortaleza de la relación lineal entre las variables de la muestra. El coeficiente de correlación puede tomar valores dentro del rango [-1, 1]. El valor -1 representa una perfecta “correlación negativa”, mientras que un valor de 1 representa una perfecta “correlación positiva”. Un valor igual a 0 representa que no existe relación entre las variables. El valor de r puede ser determinado mediante la Ecuación 2.13.

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{(\sum (x_i - \bar{x})^2)(\sum (y_i - \bar{y})^2)}} \quad [2.13]$$

La *significancia observada o valor p* de un resultado, es una medida estimada de los grados para el cual este resultado es verdadero. El valor p representa la probabilidad de error asociado a la aceptación de un resultado como válido. En algunas áreas de la investigación, $p\text{-valor} \leq 0.05$ es considerado como un nivel de error “aceptable”.

El *coeficiente de correlación cruzada* $r_{xy}(k)$ representa la correlación entre dos series, x e y ,

donde x es desfasada respecto de y en k períodos. La representación matemática de este estadístico sigue la Ecuación 2.14.

$$r_{xy}(k) = \frac{c_{xy}(k)}{s_x \cdot s_y} \quad \text{para } k = 0, \pm 1, \pm 2, \dots \quad [2.14]$$

Donde c_{xy} representa el coeficiente de correlación cruzada de retardo k , s_x es la desviación estándar de la serie x , y s_y es la desviación estándar de la serie y .

El error estándar de $r_{xy}(k)$ se puede determinar bajo el supuesto de que x e y son independientes, y se puede determinar mediante la Ecuación 2.15.

$$\text{Std.Err}(r_{xy}(k)) = \sqrt{1/(n-k)} \quad [2.15]$$

Donde n corresponde al número de observaciones de la serie.

2.5.2. Diagnóstico del Modelo

Para conocer el grado de acierto de la modelación, es necesario realizar un diagnóstico de la calidad del modelo que permita verificar si los resultados se ajustan a la serie observada. Este diagnóstico se realiza calculando indicadores de calidad sobre el modelo, los cuales permiten hacer comparaciones con otros modelos que resuelven el mismo problema. Algunos de estos modelos se basan en el concepto de linealidad y por lo tanto no son aplicables a modelos no lineales.

En la etapa de diagnóstico, además de verificar que el modelo esté adecuadamente ajustado a la serie de datos original, se verifica la calidad de generalización del modelo teniendo en cuenta una segunda y tercera colección independiente de datos. Los indicadores de calidad se utilizan tanto en la serie original como en las series de validación del modelo.

Entre los indicadores más utilizados se encuentran el *Error Cuadrático Medio ECM*, el *Error Cuadrático Medio Normalizado ECMN* y el *coeficiente de determinación r^2* .

El error cuadrático medio está dado por la Ecuación 2.16.

$$ECM = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2 \quad [2.16]$$

Donde x_i y \hat{x}_i denotan el valor real y el valor estimado, respectivamente. Un ECM cercano a cero es llamado insesgado y un ECM lejos de cero es llamado sesgado.

El error cuadrático medio normalizado por la varianza de la serie es el coeficiente dado por la Ecuación 2.17.

$$ECMN = \frac{(n-1) \sum_{i=1}^n (x_i - \hat{x}_i)^2}{n \sum_{i=1}^n (x_i - \bar{x})^2} \quad [2.17]$$

Donde \bar{x} denota el promedio de los datos. Mientras el coeficiente ECMN se acerca más a cero, se puede decir que el modelo se ajusta en mejor medida a los datos originales.

Uno de los indicadores más importantes para evaluar la calidad del modelo es el coeficiente de determinación (r^2) el cual es función del error cuadrático medio normalizado, y está dado por la Ecuación 2.18.

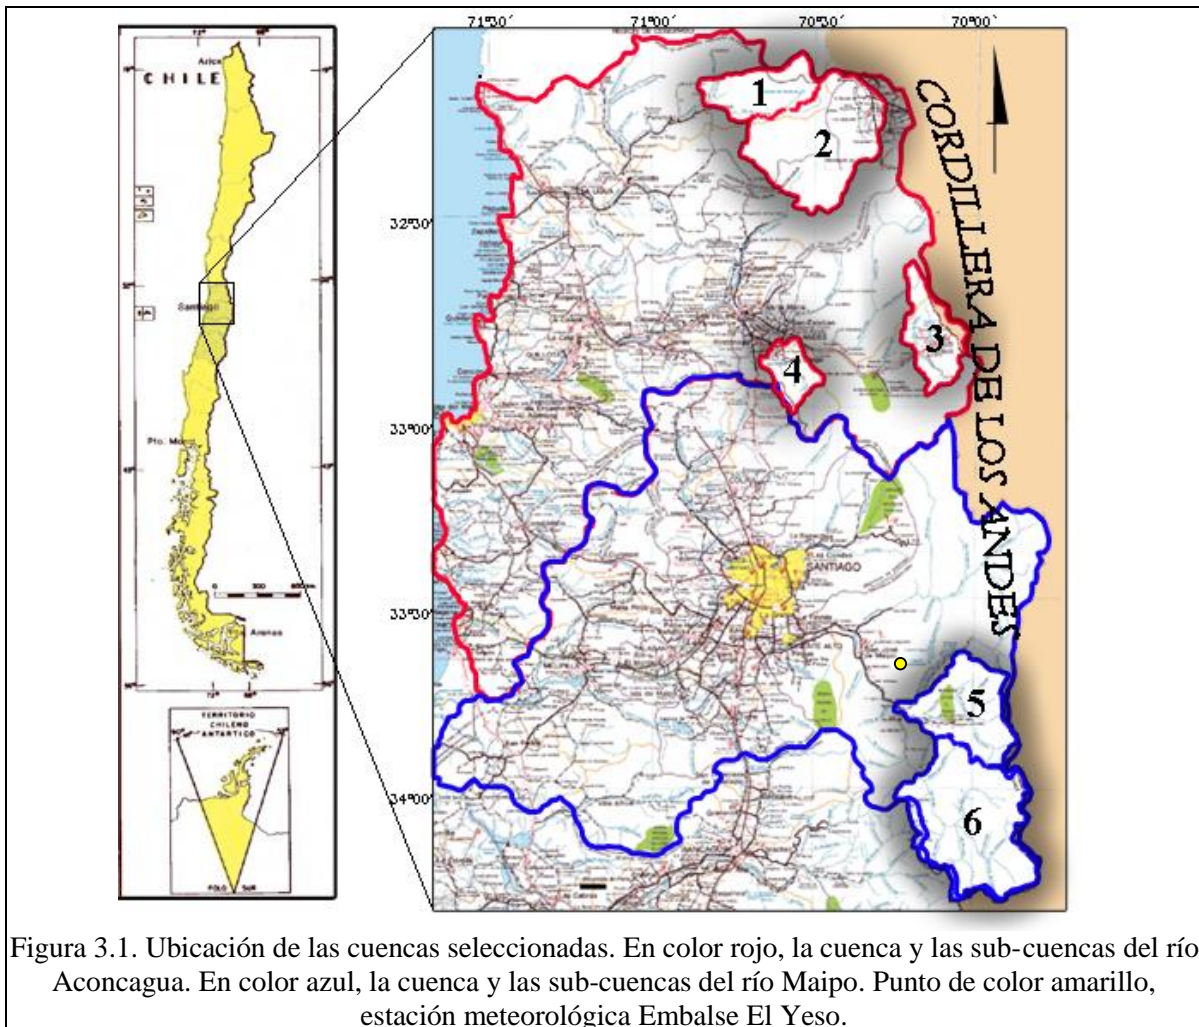
$$r^2 = 1 - \text{ECMN} \quad [2.18]$$

Para un predictor perfecto este coeficiente debe ser 1, mientras que para un predictor trivial que siempre predice el valor medio, $r^2 = 0$.

CAPÍTULO III ZONA DE MODELACIÓN

3.1. CARACTERIZACIÓN DE LA ZONA DE ESTUDIO

La región en estudio corresponde a la zona alta de las cuencas del río Aconcagua y del río Maipo, ubicadas en la V Región de Valparaíso y Región Metropolitana (RM), respectivamente. Las cuencas seleccionadas pertenecen a la zona central de Chile y se ubican entre los paralelos 32° y 34,5° de latitud sur (Figura 3.1).



Estas regiones albergan una alta densidad de estaciones fluviométricas, lo que hace posible tener un control íntegro de los recursos hídricos superficiales, sin embargo, este control no es continuo en el tiempo ya que las crecidas influyen negativamente en las mediciones, generando vacíos en el registro.

Diferentes criterios definieron finalmente la selección de 6 sub-cuencas en el área de estudio. El régimen de escorrentía y la disponibilidad de información corresponden a los principales criterios de selección, de acuerdo a los alcances de la modelación. Otros criterios fueron el área de la sub-cuenca y el grado de alteración del régimen natural.

Las cuencas seleccionadas están enumeradas en la Figura 3.1, y algunas de sus características se señalan en la Tabla 3.1, siguiendo la misma enumeración de la Figura 3.1.

Tabla 3.1. Cuencas seleccionadas, coordenadas, elevación media y área aportante.

N°	Nombre Estación	Coordenadas		Elevación media [msnm]	Área [Km ²]
		Lat. S	Lon. W		
1	Río Alicahue en Collihuay	32°19'	70°40'	1720	404
2	Río Putaendo en Resguardo los Patos	32°31'	70°36'	2620	1028
3	Río Juncal en Juncal	32°53'	70°09'	2900	379
4	Estero Pocuro en el Sifón	32°54'	70°35'	1630	214
5	Río Volcán en Queltehues	33°48'	70°12'	3020	607
6	Río Maipo en las Hualtatas	33°59'	70°10'	3400	1203

Fuente: Dirección General de Aguas.

De las 6 sub-cuencas, 4 pertenecen a la V Región y 2 a la RM. El régimen de escorrentía queda definido, entre otras variables, por la elevación media. De las cuencas seleccionadas, 5 poseen régimen nival y la restante, estero Pocuro en el Sifón (N° 4 de la Fig. 3.1 y de la Tabla 3.1) posee régimen mixto en el que predomina la componente nival. La búsqueda de cuencas de área menor se debe a la caracterización y concentración de información que se requiere para la modelación. Otro aspecto a considerar son los análisis visuales susceptibles de realizar con un conjunto de imágenes, los que entregan mejores resultados en cuencas pequeñas que en cuencas de área mayor, donde la abundancia de píxeles o información no significa un resultado más completo.

La actividad antrópica en las cuencas seleccionadas es de bajo nivel aunque no necesariamente despreciable. Lo anterior sugiere que la utilización de la información fluviométrica sea cuidadosa en los análisis de los resultados de la modelación.

3.2. CLIMA DE LA REGIÓN

En la zona central de Chile existe un ciclo anual de precipitación bien definido, caracterizado por un máximo invernal y un período estival con un monto significativamente menor que va aumentando hacia el sur. Este régimen se conoce como clima templado mediterráneo y abarca desde los 30°S hasta los 40° S, aproximadamente. Además, en la zona cordillerana se puede diferenciar el clima de frío en altura.

3.3.1. Clima Templado Mediterráneo

El Clima Templado Mediterráneo con estación seca prolongada se desarrolla prácticamente en toda la cuenca del río Aconcagua así como también en la cuenca del Río Maipo. Su característica principal es la presencia de una estación seca prolongada y un invierno bien marcado con temperaturas extremas que llegan bajo 0 grados.

Los Andes registra una temperatura media anual de 15,2° C pero los contrastes térmicos son fuertes. En verano las máximas alcanzan valores superiores a 27° C durante el día. Santiago registra una temperatura media anual de 14,5° C, pero al igual que en Los Andes, los contrastes térmicos son fuertes, alcanzando las máximas en verano valores superiores a 30° C durante el día.

Los montos de precipitación media anual registrados en el sector costero de la cuenca del Aconcagua alcanzan valores aproximados de 395 mm/año y temperaturas de 14.5° C. Por efectos del relieve, en el sector centro de la cuenca, se presentan áreas de mayor sequedad y montos menores de precipitación (261 mm/año). En sectores más elevados, las precipitaciones aumentan alcanzando valores medios anuales de 467 mm y temperaturas medias anuales de 14.1°C (Estación Vilcuya).

En la cuenca del Maipo, los montos de precipitación media anual registrados en el sector costero de la cuenca alcanzan valores aproximados de 404 mm/año y temperaturas de 14,9° C. Por efectos del relieve, en el sector centro de la cuenca (estación Quinta Normal), se presentan áreas de mayor sequedad y montos menores de precipitación (300 mm/año). En sectores más elevados, las precipitaciones aumentan alcanzando valores medios anuales de 536 mm (San José de Maipo) y temperaturas medias anuales de 14,2°C (Las Melosas).

3.3.2. Clima Frío de Altura

El Clima Frío de Altura se localiza en la Cordillera de los Andes por sobre los 3.000 metros de altura. Las bajas temperaturas y las precipitaciones sólidas, caracterizan este tipo climático, permitiendo la acumulación de nieve y campos de hielo de tipo permanentes en cumbres y quebradas de la alta Cordillera.

3.3.3. Variabilidad Climática Futura

En Chile, la distribución de las estaciones meteorológicas se concentra en la depresión intermedia hacia la costa, encontrándose un bajo número de éstas en la pre-cordillera y sólo algunas de ellas en la alta cordillera. Esto genera un conocimiento mayor en las zonas bajas, en contraste con las zonas altas donde el dominio de las variables es insuficiente, y por lo tanto, un entendimiento exiguo.

A partir de la información proporcionada por la Dirección Meteorológica de Chile, la Dirección General de Aguas y el Servicio Meteorológico de la Armada, el Departamento de Geofísica de la Universidad de Chile realizó un estudio el año 2006 sobre la variabilidad climática en Chile para el siglo XXI. A continuación se resumen algunos puntos de esta investigación (Aceituno *et al.*, 1992).

“En relación a la precipitación, durante el siglo XX se verificó una significativa disminución de esta variable en la región subtropical de Chile. En la región entre 30°S y 39°S se aprecia el predominio de una tendencia negativa hasta aproximadamente 1970. El aumento de la frecuencia de inviernos relativamente lluviosos en las décadas posteriores contribuyó a revertir la tendencia decreciente en esta región. Durante el período 1970 – 2000, la precipitación se mantuvo aproximadamente estacionaria en las regiones IV, V y Metropolitana (30°S –33°S). En general el ciclo anual sigue la declinación solar con meses invernales con menor temperatura que los de verano particularmente en latitudes mayores. Resultados preliminares sugieren que el régimen térmico superficial, en la región comprendida entre Santiago y Concepción, ha sufrido aumentos de +0.05°C/década y de +0.18°C/década en los promedios anuales de temperatura máxima y mínima, respectivamente.”

Estos panoramas, asociados a las variables analizadas, dan señal de una necesidad apremiante por los estudios a las nieves y glaciares existentes en el país, que permitan estimar la variabilidad anual de los recursos hídricos.

3.3. INFORMACIÓN FLUVIOMÉTRICA

3.3.1. Curvas de Variación Estacional

A continuación se muestran las curvas de variación estacional para 5 de las 6 cuencas seleccionadas. La estación faltante corresponde a la estación del río Alicahue en Colliguay. El período considerado para la generación de las curvas de variación estacional comprende desde el año 1970 hasta 2001.

- Estación río Putaendo en Resguardo Los Patos

En la Tabla 3.2 y la Figura 3.2, donde se muestran los caudales mensuales para distintas probabilidades de excedencia, es posible apreciar un régimen netamente nival, con los mayores caudales entre

noviembre y febrero, producto de los deshielos. Los menores caudales se producen entre abril y junio. En años secos los caudales permanecen bajos durante todo el año, sin mostrar variaciones importantes. Se producen leves aumentos de caudales entre octubre y diciembre.

Tabla 3.2. Estación río Putaendo en Resguardo Los Patos [m³/s].

Pex (%)	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Ene	Feb	Mar
5	6,49	5,75	7,55	10,91	14,99	22,78	26,53	39,85	60,99	41,29	14,19	9,41
10	5,36	4,95	6,30	8,57	11,47	16,15	21,81	33,21	42,70	26,61	10,98	7,46
20	4,25	4,11	5,06	6,40	8,30	10,78	16,85	26,29	27,73	15,78	8,05	5,63
50	2,73	2,86	3,31	3,66	4,47	5,26	9,54	15,83	12,15	6,12	4,45	3,29
85	1,58	1,74	1,93	1,84	2,08	2,57	3,95	6,54	4,40	2,33	2,14	1,70
95	1,15	1,23	1,39	1,23	1,33	1,90	2,09	2,32	2,42	1,56	1,39	1,15
Dist	L2	G	L3	L2	L2	L3	G2	G	L2	L3	L2	L2

Fuente: CADE-IDEPE Consultores, 2004.

Donde: Pex (%) corresponde a la probabilidad de excedencia, y la fila Dist entrega la abreviatura de la distribución de mejor ajuste para el mes correspondiente. La abreviatura corresponde a la siguiente:

- Normal : N
- Log-Normal 2 parámetros : L2
- Log-Normal 3 parámetros : L3
- Gumbel o de Valores Extremos Tipo I : G
- Gamma 2 parámetros : G2
- Pearson Tipo III : P3
- Log-Gamma de 2 parámetros : LG
- Log-Pearson tipo III : LP




Figura 3.2. Curva de Variación Estacional, estación río Putaendo en Resguardo Los Patos.

Fuente: CADE-IDEPE Consultores, 2004.

- Estación río Juncal en Juncal

En la Tabla 3.3 y la Figura 3.3, donde se muestran los caudales mensuales para distintas probabilidades de excedencia, es posible apreciar un régimen netamente nival, con los mayores caudales entre noviembre y marzo producto de los deshielos. Los menores caudales se producen entre junio y septiembre.

Tabla 3.3. Estación río Juncal en Juncal [m³/s].

Pex (%)	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Ene	Feb	Mar
5	6,27	4,24	3,28	2,86	2,58	2,80	6,12	10,72	18,58	24,28	17,42	10,66
10	5,77	3,87	2,91	2,66	2,36	2,60	5,48	10,13	16,48	19,90	14,78	9,59
20	5,19	3,45	2,55	2,43	2,14	2,41	4,81	9,41	14,29	15,95	12,32	8,47
50	4,17	2,77	2,06	2,02	1,85	2,10	3,81	8,05	10,98	11,17	9,18	6,78
85	3,12	2,10	1,70	1,59	1,64	1,84	2,91	6,36	8,04	8,19	7,05	5,28
95	2,60	1,77	1,56	1,37	1,56	1,71	2,50	5,38	6,71	7,25	6,33	4,60
Dist	G2	L3	L3	G2	L3	G	G	N	G	L3	L3	L3

Fuente: CADE-IDEPE Consultores, 2004.




Figura 3.3. Curva de Variación Estacional, estación río Juncal en Juncal.

Fuente: CADE-IDEPE Consultores, 2004.

- Estación estero Pocuro en El Sifón

En la Tabla 3.4 y la Figura 3.4 se puede apreciar que esta estación presenta un régimen mixto, con importante influencia pluvial y nival. Los mayores caudales se observan entre julio y noviembre, producto de lluvias invernales y deshielos primaverales. El período de menores caudales ocurre entre febrero y abril.

Tabla 3.4. Estación estero Pocuro en El Sifón [m³/s].

Pex (%)	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Ene	Feb	Mar
5	0,63	0,85	2,96	5,58	6,00	6,54	4,80	4,31	2,94	1,33	0,82	0,76
10	0,51	0,71	2,03	3,74	3,94	4,15	3,42	3,12	2,06	0,99	0,64	0,56
20	0,40	0,57	1,29	2,31	2,37	2,41	2,27	2,11	1,34	0,69	0,47	0,39
50	0,25	0,35	0,54	0,91	0,89	0,89	1,04	1,00	0,59	0,35	0,27	0,21
85	0,14	0,17	0,19	0,29	0,27	0,31	0,39	0,40	0,21	0,15	0,13	0,11
95	0,10	0,10	0,10	0,15	0,13	0,20	0,22	0,23	0,12	0,09	0,09	0,09
Dist	L2	G2	L2	L2	L2	L3	L2	L2	L2	L2	L2	L3

Fuente: CADE-IDEPE Consultores, 2004.




Figura 3.4. Curva de Variación Estacional, estación estero Pocuro en El Sifón.
Fuente: CADE-IDEPE Consultores, 2004.

- Estación río Volcán en Queltehues

En la Tabla 3.5 y la Figura 3.5, donde se presentan los caudales mensuales para distintas probabilidades de excedencia, es posible apreciar el marcado régimen nival de esta estación. Los mayores caudales se presentan en el período de deshielo, entre los meses de noviembre y marzo, alcanzando sus mayores registros en el mes de enero para años húmedos y en el mes de diciembre para los años secos. En años más húmedos se observa un aumento de caudal durante el período invernal.

Tabla 3.5. Estación río Volcán en Queltehues [m³/s].

Pex (%)	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Ene	Feb	Mar
5	12,5	4,63	5,61	4,43	4,05	6,94	8,98	20,04	40,74	47	36,8	22,1
10	8,5	3,36	4,14	3,46	3,39	5,1	7,48	18,23	36,04	39,71	29,95	18,04
20	5,33	2,3	2,86	2,57	2,71	3,52	5,89	16,03	30,79	32,27	23,34	13,8
50	2,19	1,17	1,42	1,45	1,68	1,73	3,49	11,83	22,17	21,44	14,49	7,62
85	0,73	0,59	0,6	0,72	0,76	0,72	1,58	6,66	13,98	12,51	8,06	3,01
95	0,38	0,44	0,36	0,48	0,35	0,43	0,9	3,63	10,3	8,85	5,71	1,53
Dist	L2	L3	L2	L2	G	L2	G2	N	LG	L3	L2	G2

Fuente: CADE-IDEPE Consultores, 2004.




Figura 3.5. Curva de Variación Estacional, estación río Volcán en Quiltehue.
Fuente: CADE-IDEPE Consultores, 2004.

- Estación río Maipo en Las Hualtatas

En la Tabla 3.6 y la Figura 3.6 se puede apreciar los valores asociados a las diferentes probabilidades de excedencia. Esta estación presenta un comportamiento muy similar al de la estación río Volcán en Quiltehue. También se aprecia que en años secos el caudal máximo ocurre en diciembre y en años húmedos en enero.

Tabla 3.6. Estación río Maipo en Las Hualtatas [m³/s].

Pex (%)	Abr	May	Jun	Jul	Ago	Sep	Oct	Nov	Dic	Ene	Feb	Mar
5	34,2	27,7	27,0	18,7	16,5	17,1	27,6	59,7	106,8	162,0	97,2	52,2
10	29,4	24,0	22,5	17,0	15,6	16,2	26,1	55,8	95,4	124,7	77,7	46,2
20	24,9	20,4	18,5	15,3	14,4	15,2	24,5	51,3	83,2	92,4	60,3	39,9
50	18,9	15,6	13,5	12,7	12,5	13,5	21,6	43,6	64,1	55,8	39,8	30,1
85	14,8	12,2	10,2	10,4	10,5	11,6	18,3	35,2	46,5	35,1	27,5	21,2
95	13,3	10,9	9,2	9,4	9,5	10,6	16,6	30,9	38,5	29,1	23,7	17,3
Dist	L3	L3	L3	G	L2	L2	G2	N	L2	L3	L3	L2

Fuente: CADE-IDEPE Consultores, 2004.




Figura 3.6. Curva de Variación Estacional, estación río Maipo en Las Hualtatas.
Fuente: CADE-IDEPE Consultores, 2004.

3.3.2. Información Disponible

La información fluviométrica utilizada es a nivel medio diario y comprende desde Enero del año 2000 hasta Marzo del año 2008. La información de carácter oficial es hasta Diciembre del año 2007 en tanto que los primeros meses del presente año corresponde a información no oficial. Esta información ha sido proporcionada por la Dirección General de Aguas y, es mostrada para cada cuenca en las Figuras 3.7, a 3.13.

La concentración de la precipitación durante los meses de mayo, julio y agosto en la alta cordillera genera la acumulación de nieve. Esto da lugar a la estacionalidad que poseen los caudales en cuencas de régimen nival, que se manifiesta con grandes volúmenes de agua durante la época estival.

La variabilidad anual de los volúmenes muestra la alternancia entre años secos, normales y húmedos, aunque no es posible hacer una caracterización definida por la escasa cantidad de años considerados. Los registros en las 6 cuencas indican que los años hidrológicos 2003-04 y 2004-05 fueron más secos que los años restantes.

La generación de grandes caudales de corta intensidad como se observa en la Figura 3.10, presentes durante el período de lluvias, es causada por la precipitación sobre la nieve en la que se suman los efectos de escorrentía producto de la lluvia y el derretimiento acelerado de la nieve producto del traspaso de calor que ofrece el agua líquida sobre el manto.

El registro completo de la información fluviométrica, de carácter oficial, se encuentra en el Anexo Magnético.




Figura 3.7. Registro de caudales medios diarios en la estación río Alichahue en Collihuay.




Figura 3.8. Registro de caudales medios diarios en la estación río Putaendo en Resguardo Los Patos.




Figura 3.9. Registro de caudales medios diarios en la estación río Juncal en Juncal.




Figura 3.10. Registro de caudales medios diarios en la estación estero Pocuro en El Sifón.




Figura 3.11. Registro de caudales medios diarios en la estación río Volcán en Queltehues.




Figura 3.4. Registro de caudales medios diarios en la estación río Maipo en Las Hualtatas.

CAPÍTULO IV ANÁLISIS DE LA INFORMACIÓN SATELITAL

4.1. SELECCIÓN DE IMÁGENES

En la selección del tipo de imágenes se busca considerar los elementos regionales que han sido incluidos en la producción de las imágenes puesto que, de acuerdo a la latitud, puede suceder que los supuestos no sean válidos en la zona de estudio lo que afectaría de manera considerable los resultados. Un ejemplo es lo que ocurre con las imágenes MOD10 en las que se considera un umbral NDSI de 0.4 para diferenciar entre nieve y no-nieve en regiones con vastas zonas forestadas, lo que permite aceptar un umbral de este nivel.

En Chile, las características fisiográficas son diferentes, con una vegetación que se desarrolla hasta una determinada cota, por lo que durante la época de deshielo, las zonas desprovistas de vegetación son amplias y el criterio no necesariamente es válido.

En el presente trabajo se utilizará sólo un tipo de imágenes derivados de MODIS, puesto que los procesos de pre-procesamiento de imágenes antes de su empleo final, son lentos y extensos. La discusión previa sugiere la utilización de imágenes MOD09, que permita la modificación del umbral NDSI a un valor mayor, de acuerdo a las condiciones estacionales, sin embargo, mediante la validación puntual de las imágenes podrá tenerse una mejor apreciación de esta discusión.

En este trabajo, la escala temporal óptima es a nivel diario de manera de hacer un seguimiento lo más continuo posible al manto, con un registro de 5 años como mínimo para incluir diferentes escenarios hidrológicos; la escala espacial útil va desde los 15 metros a cientos de metros, sin embargo, el enfoque a nivel de cuenca con un área media de 1000 km² hace razonable la utilización de escalas mayores llegando a 1000 metros; finalmente, el ancho espectral debe permitir diferenciar elementos con cubierta de nieve de otras cubiertas.

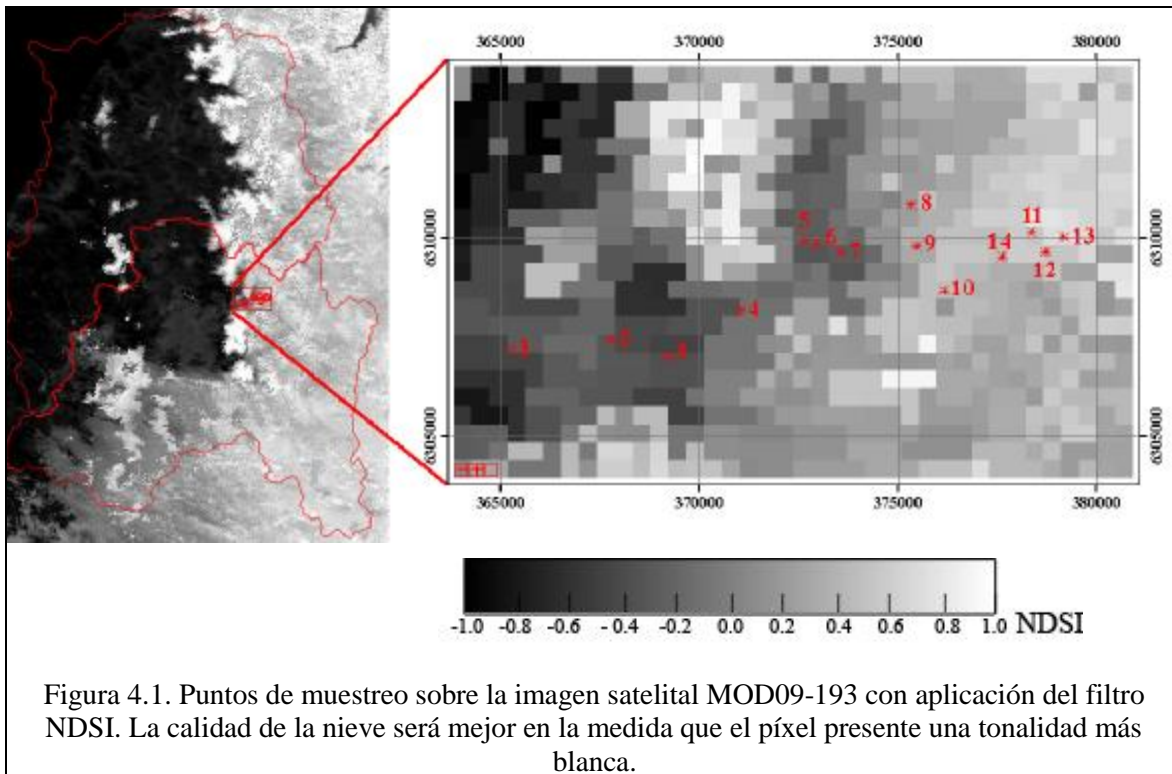
4.2.1. Validación puntual de las Imágenes

La validación puntual de las imágenes corresponde a la comparación entre la información observada en terreno y la imagen correspondiente a la misma fecha. Consiste en recolectar información en un punto de coordenadas conocidas y luego contrastar con la información obtenida de la imagen en el mismo lugar. Esta labor puede ser aplicada sobre cada imagen o un grupo representativo de ellas, por lo tanto, exige un tiempo importante para el muestreo.

La validación se realizó para la imagen MOD09, correspondiente al 12 de Julio (N°193, de acuerdo al calendario juliano) del año 2007, mediante 14 puntos de muestreo en la localidad “Camino a Farellones”, comuna de Lo Barnechea, Santiago, Región Metropolitana. En la Figura 4.1, se aprecian los puntos de muestreo (números en color rojo) sobre la imagen MOD09 con filtro NDSI.

Los resultados indican que un umbral de 0.4 para el filtro NDSI es válido para aceptar la existencia de una cubierta de nieve con nieve de buena calidad (> 10 cm. de espesor), por lo que se puede aceptar el uso de imágenes MOD09 en la región de estudio durante el período de acumulación, pues es válido uno de los supuestos más importantes.

Sin embargo, el registro de las imágenes MOD10 está disponible desde el 13 de Septiembre del año 2000, en tanto que el registro de imágenes MOD09 está disponible desde el 26 de Febrero del mismo año, lo que significa un registro mayor para el desarrollo de un modelo que tiene como principal restricción la información disponible. La solución a esta condición es el uso de imágenes MOD09, que poseen un registro más amplio y sobre las cuales se puede realizar un mayor número de análisis remotos.



Los resultados de la validación se detallan en el Anexo I.

4.2.2. Registro de Imágenes a utilizar

De acuerdo a los registros satelitales sobre la zona de estudio, existen 359 imágenes MOD09 desde el año 2000 hasta el año 2007. Las bandas espectrales comunes para las imágenes MOD09 incluyen el rango espectral de color verdadero y algunas bandas en el rango infrarrojo. Estas se muestran en la Tabla 4.1.

Tabla 4.1. Bandas espectrales comunes para las imágenes MOD09.

Banda #	Rango Espectral [μm]	Nombre
1	0,620-0,670	<i>Red</i>
2	0,841-0,876	<i>Near-Infrared</i>
3	0,459-0,479	<i>Blue</i>
4	0,545-0,565	<i>Green</i>
5	1,230-1,250	<i>Near-Infrared</i>
6	1,628-1,652	<i>Mid-Infrared</i>
7	2,105-2,155	<i>Mid-Infrared</i>

Fuente: <http://modis-land.gsfc.nasa.gov>.

El detalle de imágenes por año se muestra en la Tabla 4.2. El número descrito en dicha tabla corresponde a la fecha en calendario juliano y concierne a la imagen compuesta por las 8 imágenes previas obtenidas diariamente por el sensor MODIS.

La cubierta nubosa se extiende por períodos mayores a 24 horas, lo que sugiere el empleo de imágenes resultantes de la composición de 8 imágenes diarias en lugar de imágenes diarias que finalmente resultarán descartadas. La cubierta nubosa puede mantenerse por períodos mayores a 8 días, impidiendo la comparación entre 2 imágenes sucesivas, sin embargo, el número de imágenes susceptibles de analizar

debido a este fenómeno es bajo, lo que representa un problema menor. La escala espacial para estos productos es de 15 segundos de arco ($\approx 500\text{m}$).

Tabla 4.2. Registro de imágenes utilizadas de acuerdo al calendario juliano.

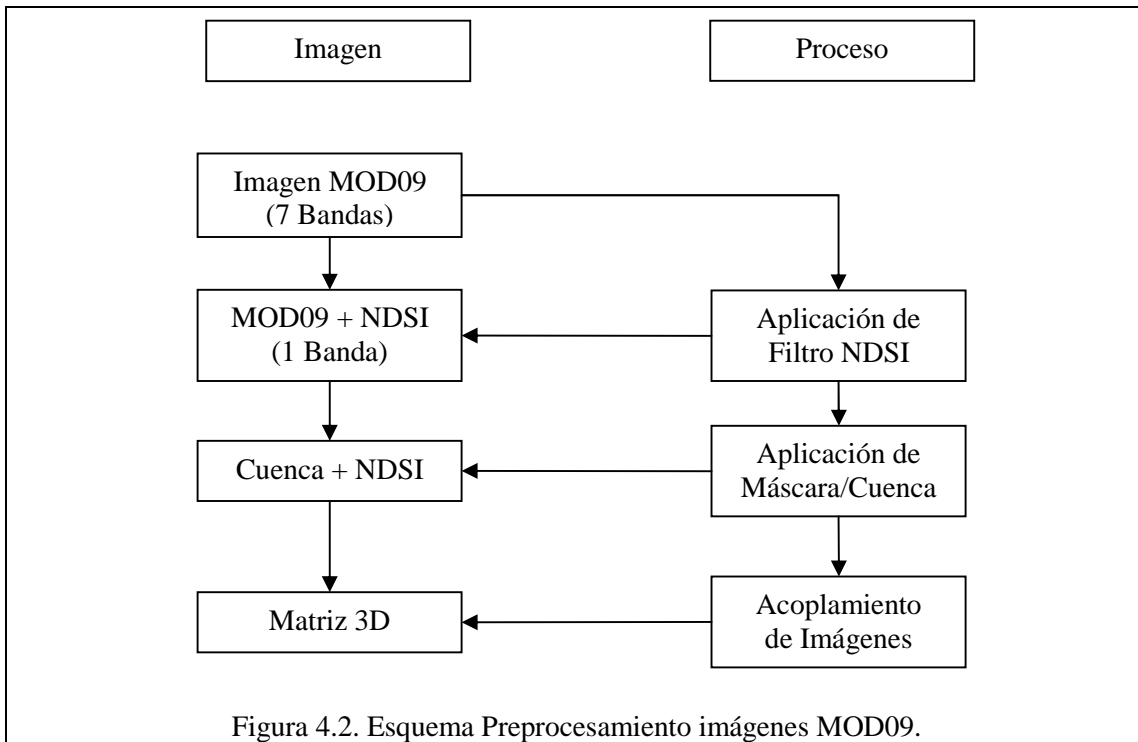
Fecha	Año															
	2000		2001		2002		2003		2004		2005		2006		2007	
1-ENE / 4-JUL	-	185	1	185	1	185	1	185	1	185	1	185	1	185	1	185
9-ENE / 12-JUL	-	193	9	193	9	193	9	193	9	193	9	193	9	193	9	193
17-ENE / 20-JUL	-	201	17	201	17	201	17	201	17	201	17	201	17	201	17	201
25-ENE / 28-JUL	-	209	25	209	25	209	25	209	25	209	25	209	25	209	25	209
2-FEB / 5-AGO	-	217	33	217	33	217	33	217	33	217	33	217	33	217	33	217
10-FEB / 13-AGO	-	225	41	225	41	225	41	225	41	225	41	225	41	225	41	225
18-FEB / 21-AGO	-	233	49	233	49	233	49	233	49	233	49	233	49	233	49	233
26-FEB / 29-AGO	57	241	57	241	57	241	57	241	57	241	57	241	57	241	57	241
6-MAR / 6-SEP	65	249	65	249	65	249	65	249	65	249	65	249	65	249	65	249
14-MAR / 14-SEP	73	257	73	257	73	257	73	257	73	257	73	257	73	257	73	257
22-MAR / 22-SEP	81	265	81	265	81	265	81	265	81	265	81	265	81	265	81	265
30-MAR / 30-SEP	89	273	89	273	89	273	89	273	89	273	89	273	89	273	89	273
7-ABR / 8-OCT	97	281	97	281	97	281	97	281	97	281	97	281	97	281	97	281
15-ABR / 16-OCT	105	289	105	289	105	289	105	289	105	289	105	289	105	289	105	289
23-ABR / 24-OCT	113	297	113	297	113	297	113	297	113	297	113	297	113	297	113	297
1-MAY / 1-NOV	121	305	121	305	121	305	121	305	121	305	121	305	121	305	121	305
9-MAY / 9-NOV	129	313	-	313	129	313	129	313	129	313	129	313	129	313	129	313
17-MAY / 17-NOV	137	321	137	321	137	321	137	321	137	321	137	321	137	321	137	321
25-MAY / 25-NOV	145	329	145	329	145	329	145	329	145	329	145	329	145	329	145	329
2-JUN / 3-DIC	153	337	153	337	153	337	153	337	153	337	153	337	153	337	153	337
10-JUN / 11-DIC	161	345	161	345	161	345	161	345	161	345	161	345	161	345	161	345
18-JUN / 19-DIC	169	353	-	353	169	353	169	353	169	353	169	353	169	353	169	353
26-JUN / 27-DIC	177	361	177	361	177	361	177	361	177	361	177	361	177	361	177	361
Total Imágenes	39		44		46		46		46		46		46		46	

Obs.: (-) No existe registro de imagen.

4.2. PROCESAMIENTO DE LAS IMÁGENES: COBERTURA NIVAL

Para trabajar la información remota se ideó la manera de elaborar matrices del tipo espacio temporal, que permitieran realizar un seguimiento continuo para cada cuenca en estudio. Este procesamiento requirió el uso de diferentes software que permitieran finalmente la construcción de matrices en 3-D que recogieran la información de cada imagen generando una matriz temporal. Las diferentes etapas del preprocesamiento se esquematizan en la Figura 4.2.

Para trabajar con la información matricial de forma más expedita, se empleó el software Matlab. Las etapas del preprocesamiento y las diferentes rutinas creadas se describen con mayor detalle en el Anexo II.



4.2.1. Relación entre la Cobertura de Nieve y la Escorrentía de Deshielo

Desde el punto de vista hidrológico, la escorrentía de deshielo debiera estar sujeta a cambios en la cobertura de nieves. Para la evaluación de esta interrogante, es necesario definir el área cubierta de nieve aportante a la escorrentía en un punto. La región aportante a la escorrentía estará constituida por la hoya hidrográfica unida a otras cuencas mediante aportes no controlados, como flujos sub-superficiales, flujos subterráneos y afloramientos. Dichos aportes no serán incluidos en el análisis por el desconocimiento parcial sobre las cuencas en estudio, quedando sólo la región delimitada por las altas cumbres para la definición de la cuenca hidrográfica como región aportante.

El área cubierta de nieve queda definida como la suma de aquellos píxeles dentro de la cuenca que están sobre un umbral límite multiplicado por el área de un píxel. Cada píxel posee un área igual a 0.25 km^2 . Cabe recordar que se desea analizar los fenómenos a escala estacional, dada las características de la información disponible, durante el período 2000-2007.

El registro continuo de imágenes permite analizar la variabilidad espacio temporal de la cubierta de nieve definida mediante un valor umbral NDSI aplicado para todo el registro. La estimación de esta área porcentual de la cuenca es comparada con el registro de la escorrentía media asociada a la misma zona y al mismo período de la imagen, es decir, cada 8 días.

Para explicar el efecto de un determinado umbral de NDSI en la generación de cada serie, se definieron 3 umbrales diferentes: 0.9; 0.7, y 0.4. El resultado de la comparación entre la serie de escorrentía y la serie de cobertura nival obtenida para cada umbral, aplicada sobre la cuenca del río Juncal en Juncal, se aprecia en las Figuras 4.3 a 4.5.




Figura 4.3. Escorrentía media ocurrida en 8 días (línea azul) y porcentaje de área cubierta de nieve (línea roja) para la cuenca del río Juncal en Juncal. Umbral NDSI = 0.9.




Figura 4.4. Escorrentía media ocurrida en 8 días (línea azul) y porcentaje de área cubierta de nieve (línea roja) para la cuenca del río Juncal en Juncal. Umbral NDSI = 0.7.

A partir de los gráficos anteriores, se destaca la estabilización de la serie de área cubierta de nieve hacia un valor cercano al 100%, en la medida que el umbral NDSI es menor o cercana a 0.4. Para un umbral mayor como 0.9, se observa que la variable está sujeta a cambios extremos período a período, es decir, la curva posee abruptas alteraciones entre valores altos y bajos, lo que no es esperable en la metamorfosis del manto.

Para comparar los resultados obtenidos, se presentan además los gráficos para la cuenca del río Volcán en Queltehues, para valores umbrales de NDSI, 0.9, 0.7 y 0.4, en el período 2002-2004. Éstos se muestran en las Figuras 4.6 y 4.7.

Del análisis de las Figuras 4.6 y 4.7, correspondientes a las cuencas del río Juncal y río Volcán para diferentes valores umbrales de NDSI (0.9, 0.7 y 0.4), se desprenden diferentes respuestas en torno al entendimiento de la hidrología de nieves. Éstos se discuten a continuación.




Figura 4.5. Escorrentía media ocurrida en 8 días (línea azul) y porcentaje de área cubierta de nieve (línea roja) para la cuenca del río Juncal en Juncal. Umbral NDSI = 0.4.





Figura 4.6. Escorrentía media ocurrida en 8 días (línea azul) y porcentaje de área cubierta de nieve (línea naranja NDSI=0.9; línea verde NDSI=0.7; línea roja NDSI=0.4) para la cuenca del río Juncal.

En primer lugar se visualiza una clara dependencia entre la dinámica del manto y la escorrentía de deshielo a lo largo del período analizado. Los procesos de almacenamiento y derretimiento del manto de nieves se desarrollan desde abril hasta octubre y desde noviembre hasta febrero, respectivamente; en cambio, la escorrentía de deshielo se desarrolla desde septiembre hasta marzo con un máximo entre los meses de diciembre y enero. Además, la relación entre las series muestra grandes volúmenes de escorrentía de deshielo que son precedidos por grandes almacenamientos de nieve. Por el contrario, aquellos años más secos (2003 y 2004) fueron precedidos por acumulaciones de nieve más pobres.

La duración temporal de cada fenómeno es variada y dependerá de múltiples factores que afectan en forma directa e indirecta a cada uno. En general, la existencia del manto se extenderá por un período de mayor duración que la escorrentía producida. Además, se observa que el proceso de derretimiento acelerado tiende a desarrollarse a una misma tasa que la crecida de deshielo (en valor absoluto).



Se distingue también, la existencia de un área mínima cubierta por nieve durante los meses más cálidos, lo que indica la presencia de glaciares o nieves eternas. En el caso de la cuenca del río Juncal, donde existen varios glaciares siendo el de mayor importancia el glaciar Juncal Norte, la Figura 4.6 muestra que para un NDSI de 0.4 existe al menos un área del 5% ($\approx 19 \text{ Km}^2$), que no desaparece o que no se derrite.



En otro aspecto, el almacenamiento de nieve en la cordillera está limitado por sus características geomorfológicas. En la determinación del área cubierta de nieve existirá, por tal motivo, un valor máximo que puede corresponder al área total de la cuenca o a un área menor a ésta. En la medida que se alcancen estos valores de máximo, se desarrollará la acumulación por capas, es decir, luego que la tormenta cubre el total de la cuenca con nieve, al no existir un derretimiento acelerado, la tormenta siguiente podría ser capaz de cubrir nuevamente la región generando una nueva capa de nieve. En las Figuras 4.6 y 4.7 se distingue este fenómeno en el que los valores máximos de cobertura pueden ser alcanzados en diferentes años. En la Figura 4.6 el valor máximo para un umbral NDSI de 0.4 es de un 100% y es alcanzado durante 6 años.

En un análisis visual se puede apreciar fácilmente aquellas imágenes que proveen irregularidad sobre la serie, puesto que el área de cobertura nival sujeta a acumulación o derretimiento generado en un período de 8 días, sólo puede alterar de manera transitoria la serie, es decir, luego de un aumento brusco del área cubierta producto de una tormenta, es inesperado tener un valor mucho menor o nulo de cobertura en el período siguiente. Este comportamiento se puede encontrar en zonas urbanas donde los procesos de derretimiento son acelerados mediante técnicas artificiales. La alteración de la serie demuestra la imprecisión que puede otorgar el análisis remoto cuando se desconoce la información real. Una regla heurística a este tipo de problema es la eliminación de la imagen en el análisis posterior. En la búsqueda de una relación entre las series analizadas, se aplican herramientas estadísticas que permitan identificar algún modelo simple como un modelo lineal. Esta discusión se aborda en el punto 4.2.2.

Es importante recordar que de las 6 cuencas seleccionadas, sólo la cuenca del estero Pocuro en El Sifón posee régimen mixto. Esta particularidad es mostrada en las Figuras 4.8 y 4.9, donde se presenta la comparación de las series en dicha cuenca.

Sobre la cuenca del estero Pocuro en El Sifón se tiene un problema relativo a la altitud a la cual ésta se encuentra, en la que el desarrollo de tormentas de agua líquida genera crecidas en el período de acumulación de la nieve. Por lo tanto, en la comparación de las dos series, como se observa en las Figuras 4.8 y 4.9, existirán grandes fluctuaciones en torno a los caudales observados, generándose mayor

incertidumbre con su relación directa con el área del manto de nieve.



Los resultados de la comparación entre las series temporales, para cada cuenca, se encuentran en el Anexo Magnético.

4.2.2. Desfase Temporal entre la Cobertura de Nieve y la Escorrentía de Deshielo

Una vez que la nieve derretida ha alcanzado la base del manto, el agua puede fluir libremente por el suelo o infiltrarse en éste, dependiendo de las características del suelo. En zonas urbanas la compresión del suelo es periódica lo que no permite la infiltración, en cambio en regiones naturales los procesos de congelamiento y descongelamiento permiten un almacenamiento mayor de agua (Dunne and Black, 1971; Kane and Stein, 1983; Kane & Chacho, 1990; Williams and Smith, 1991). De esta manera, los máximos caudales ocurridos durante los meses cálidos provienen principalmente del almacenamiento del agua en el suelo y no del derretimiento de la nieve (Shanley and Chalmers, 1999) lo que explica el desfase temporal de la cobertura de nieve y la crecida de deshielo.

Debido a la interferencia sobre la serie de cobertura de nieve producida por aquellas imágenes con gran

contaminación atmosférica, se decidió eliminar algunas imágenes antes de proseguir con el análisis. La eliminación de algunas de ellas se realizó de acuerdo a 3 criterios:

- estudio visual en la que se distinguen patrones de cobertura nubosa;
- comparación con el valor porcentual de cobertura nival de la imagen precedente;
- el total de imágenes eliminadas no fuera mayor al 10% del total.

El primer criterio es el más simple, por cuanto representa un análisis remoto cualitativo donde se comparan diferentes situaciones o imágenes, en la que la percepción del experto define la eliminación de algunas imágenes. Al unir este criterio a un segundo criterio, donde se comparan los valores de porcentaje de área cubierta con valores precedentes y posteriores, la decisión de eliminar o no, pasa a tener un carácter cuantitativo y el resultado es más robusto. El tercer criterio se emplea para mantener la representatividad de la serie desde el punto de vista estadístico, pues al eliminar un porcentaje mayor se puede estar sesgando la serie.

Cabe destacar que el segundo criterio estuvo afecto a la naturaleza del fenómeno sobre la escala temporal de las mediciones (8 días), en la que es inesperado tener una variabilidad extrema en períodos seguidos, vale decir, dada una tormenta que genere una cobertura del 80% de la cuenca, sería dudoso observar a la semana siguiente una cobertura del 50% sin observar un incremento en el registro fluviométrico asociado al derretimiento acelerado. De esta manera, la regla de eliminación fue definida por una diferencia mayor al 10% ó 20% en el porcentaje de área cubierta considerando un umbral NDSI=0.5 ó 0.4, dependiendo además de cada cuenca, la época del año y la respuesta en la escorrentía. De esta manera, un ejemplo de aplicación de la regla es el siguiente: si la imagen presenta un patrón visual anormal y algo confuso, la aplicación del segundo criterio es empleada sobre la base de la imagen precedente y/o siguiente; si la diferencia es mayor a un cierto valor límite de área cubierta, lo que corresponde a un derretimiento hiperacelerado, la imagen es eliminada. El resultado de la eliminación de imágenes en cada cuenca se resume en la Tabla 4.3. Es importante señalar que en 3 cuencas estudiadas, el porcentaje de eliminación es mayor al 10%, sin embargo, este resultado fue aceptado considerando que el porcentaje sigue siendo bajo. El registro restante es utilizado para el análisis de las series, el que se presenta a continuación.

Tabla 4.3. Número de imágenes eliminadas para cada cuenca.

Nombre Estación	Nº Inicial de Imágenes	Nº Imágenes Eliminadas	Porcentaje de Eliminación [%]	Nº Final de Imágenes
Río Alicahue en Collihuay	359	11	3.1	348
Río Putaendo en Resguardo los Patos	359	28	7.8	331
Río Juncal en Juncal	359	44	12.3	315
Estero Pocuro en El Sifón	359	19	5.3	340
Río Volcán en Queltehues	359	45	12.5	323
Río Maipo en Las Hualtatas	359	38	10.6	323

Se prevé que el desfase temporal entre la cobertura de nieve y la escorrentía de deshielo posee cambios a lo largo de Chile, sujeto principalmente a las condiciones fisiográficas. Bajo esta perspectiva, también se pueden esperar diferencias entre la alta cordillera y la pre-cordillera.

Para determinar la diferencia temporal entre las variables, se generaron correlaciones lineales cruzadas que permitieran seguir período a período la correlación entre las variables. En la Figura 4.10 se muestra el resultado de este análisis aplicado sobre la cuenca del río Maipo en las Hualtatas considerando un desfase de 40 períodos entre las variables y un NDSI de 0.9.

Al observar la Figura 4.10 se distingue una curva que corresponde a un fenómeno estacionario, en el que se mantienen invariantes sus estadísticos, sin tendencias significativas. El número de puntos considerados para este análisis corresponden al número de imágenes disponibles en el período 2000-2007,

resultante luego de la eliminación parcial de ellas, es decir, 323 imágenes.

En relación a la correlación, se observa que las variables alcanzan su mayor valor con un desfase de 13 períodos, lo que indica que el retraso entre las series es de 104 días. Esto indica que el retardo entre los fenómenos estudiados es de aproximadamente 3 meses y 15 días, en la cuenca seleccionada.

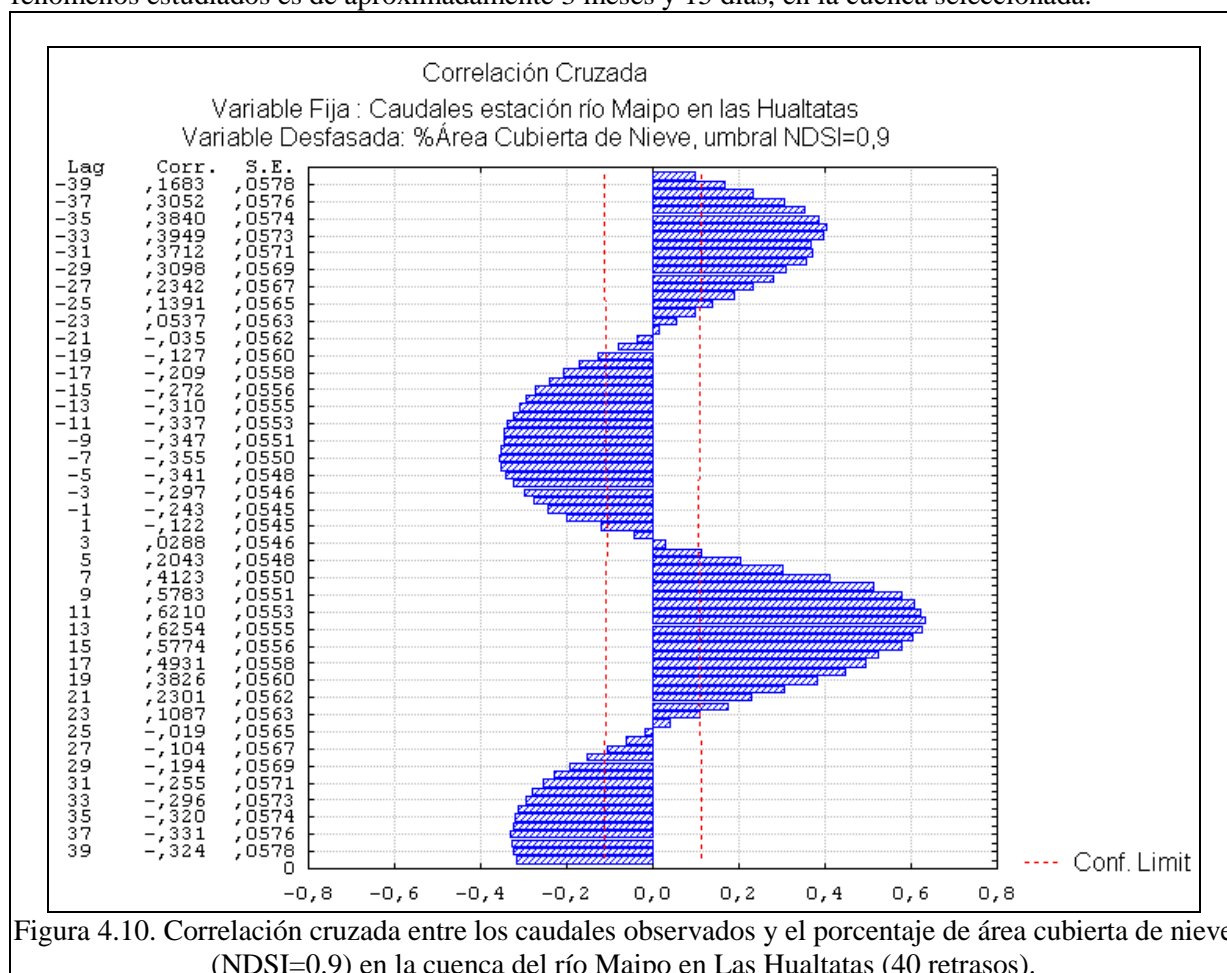


Figura 4.10. Correlación cruzada entre los caudales observados y el porcentaje de área cubierta de nieve (NDSI=0.9) en la cuenca del río Maipo en Las Hualtatas (40 retrasos).

Además, se observa que para alcanzar la mayor correlación negativa, es necesario realizar un desfase negativo de 9 períodos, lo cual corresponde a 72 días (2 meses y 15 días aproximadamente). Este período corresponde al desfase necesario en el que una variable crece y la otra decrece. La unión de los 2 desfases analizados corresponde a 6 meses e indica la estacionalidad de los fenómenos estudiados.

En las Tablas 4.4 a 4.9 se muestran los resultados de desfase temporal entre las series obtenidos para la mayor correlación positiva considerando diferentes valores umbrales NDSI.

Tabla 4.4. Desfase temporal para la mayor correlación positiva, río Alicahue.

NDSI	Períodos Desfase	Meses Desfase	Correlación Cruzada	Error Std.
0.9	9	2.4	0.57	0.055
0.8	10	2.7	0.69	0.055
0.7	10	2.7	0.67	0.055
0.6	11	2.9	0.67	0.055
0.5	11	2.9	0.68	0.055
0.4	10	2.7	0.67	0.055

Tabla 4.5. Desfase temporal para la mayor correlación positiva, río Putaendo.

NDSI	Períodos Desfase	Meses Desfase	Correlación Cruzada	Error Std.
0.9	9	2.4	0.58	0.055
0.8	12	3.2	0.65	0.055
0.7	14	3.7	0.68	0.056
0.6	14	3.7	0.68	0.056
0.5	14	3.7	0.68	0.056
0.4	14	3.7	0.67	0.056

Tabla 4.6. Desfase temporal para la mayor correlación positiva, río Juncal.

NDSI	Períodos Desfase	Meses Desfase	Correlación Cruzada	Error Std.
0.9	13	3.5	0.61	0.055
0.8	15	4.0	0.66	0.056
0.7	17	4.5	0.66	0.056
0.6	17	4.5	0.66	0.056
0.5	19	5.1	0.66	0.056
0.4	19	5.1	0.65	0.056

Tabla 4.7. Desfase temporal para la mayor correlación positiva, estero Pocuro.

NDSI	Períodos Desfase	Meses Desfase	Correlación Cruzada	Error Std.
0.9	11	2.9	0.64	0.055
0.8	15	4.0	0.66	0.056
0.7	15	4.0	0.64	0.056
0.6	15	4.0	0.64	0.056
0.5	15	4.0	0.64	0.056
0.4	15	4.0	0.63	0.056

Tabla 4.8. Desfase temporal para la mayor correlación positiva, río Volcán.

NDSI	Períodos Desfase	Meses Desfase	Correlación Cruzada	Error Std.
0.9	12	3.2	0.63	0.055
0.8	14	3.7	0.59	0.056
0.7	17	4.5	0.61	0.056
0.6	17	4.5	0.62	0.056
0.5	17	4.5	0.62	0.056
0.4	17	4.5	0.62	0.056

Tabla 4.9. Desfase temporal para la mayor correlación positiva, río Maipo.

NDSI	Períodos Desfase	Meses Desfase	Correlación Cruzada	Error Std.
0.9	12	3.2	0.63	0.055
0.8	15	4.0	0.60	0.056
0.7	18	4.8	0.64	0.056
0.6	17	4.5	0.64	0.056
0.5	17	4.5	0.63	0.056
0.4	17	4.5	0.62	0.056

El resultado general indica que el desfase entre las series es de 3 a 5 meses, lo que señala aproximadamente el retardo entre las primeras tormentas de acumulación nival y el inicio de la escorrentía de deshielo.

Los diferentes desfases obtenidos entre NDSI= 0.4 y 0.7 fueron promediados para determinar el desfase de los fenómenos por cada cuenca considerando los valores de correlación cruzada. Los resultados para

NDSI de 0.9 y 0.8 fueron marginados por tener asociado valores de correlación diferentes a la media de los demás valores (entre NDSI= 0.4 y 0.7). El resumen de los desfases por cuenca se muestra en la Tabla 4.10.

Tabla 4.10. Cuencas seleccionadas, coordenadas, elevación media y desfase entre las series.

N°	Nombre Estación	Coordenadas		Elevación media [msnm]	Meses de Desfase
		Lat. S	Lon. W		
1	Río Alicahue en Collihuay	32°19'	70°40'	1720	2.8
2	Río Putaendo en Resguardo los Patos	32°31'	70°36'	2620	3.6
3	Río Juncal en Juncal	32°53'	70°09'	2900	4.6
4	Estero Pocuro en El Sifón	32°54'	70°35'	1630	4.0
5	Río Volcán en Queltehues	33°48'	70°12'	3020	4.5
6	Río Maipo en Las Hualtatas	33°59'	70°10'	3400	4.4

Este resultado es particularmente interesante cuando se comparan las 3 cuencas de mayor altitud media, las que poseen 4.5 meses de desfase en promedio,

Otro aspecto interesante de resaltar es la tendencia hacia desfases mayores en la medida que se avanza en latitud, lo que podría indicar menores tiempos de desfase al norte y mayores períodos al sur. Este resultado debe ser analizado con mayor cuidado, para lo cual es necesaria la incorporación de otras cuencas ubicadas a mayores y menores latitudes.

En relación a la variabilidad de los desfases a diferentes longitudes, se tiene que ésta es mayor para longitudes menores, lo que es explicado por el mayor contenido de frío que almacena la nieve al estar a una mayor altura con una menor influencia de factores externos que pueden acelerar su derretimiento, como precipitación líquida, cobertura vegetal y la geomorfología. Este fenómeno también debe ser estudiado con mayor profundidad, mediante el estudio a otras cuencas.

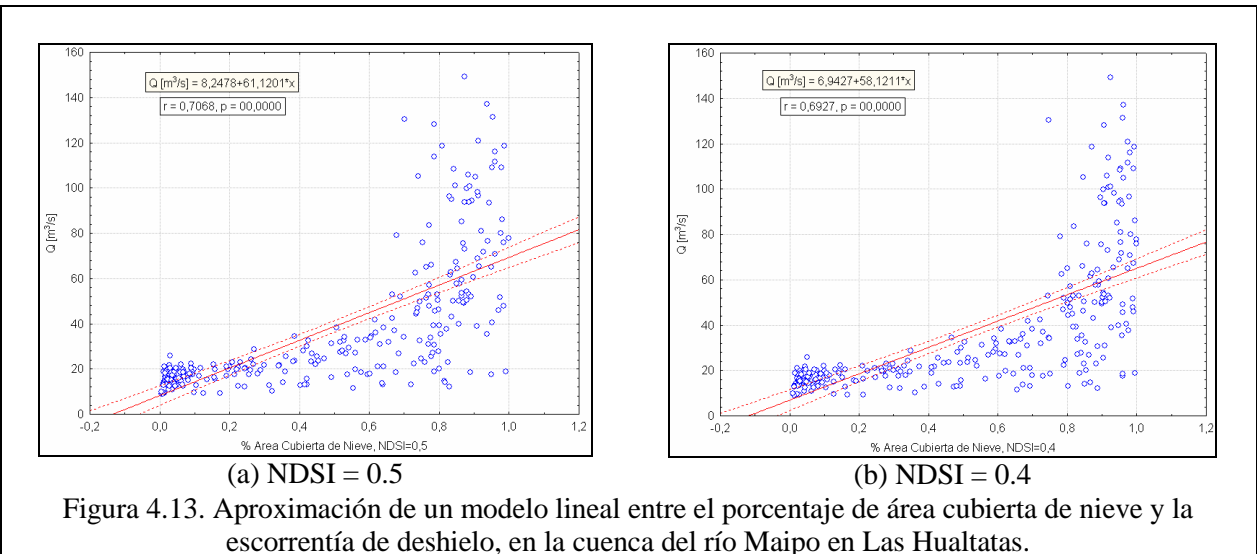


Una vez obtenido el desfase entre las series, el paso siguiente es la búsqueda de una relación matemática entre la cobertura y la escorrentía de deshielo.

4.2.3. Búsqueda de un Modelo Lineal entre Cobertura de Nieve y la Escorrentía de Deshielo

Sobre la base que no existen investigaciones en torno a una relación entre las variables de interés dentro de la región de estudio, y que incluyan un vasto número de imágenes, se determinó un primer modelo de aproximación lineal, en el que la variable independiente corresponda a la cobertura de nieve (desfasada) y la variable dependiente al caudal de deshielo. Los resultados de la correlación lineal aplicada en la cuenca del río Maipo en Las Hualtatas, para los diferentes valores umbrales de NDSI, se muestran desde la Figura 4.11 hasta la Figura 4.13.



El modelo lineal se ajusta razonablemente a los datos, explicando dicha relación por sobre un 60%, con un nivel de confianza p-valor <0.001. Este resultado es interesante si se considera que las variables están sujetas a innumerables factores que alteran su variabilidad en el tiempo, de forma individual como en su conjunto.

Al observar la nube de puntos de cada gráfico, se advierte que el modelo lineal no posee un buen ajuste, y que a medida que el umbral es cercano a 0.4, la tendencia de ajuste es a uno de tipo exponencial. Esto se debe a la estabilización de la serie de área cubierta durante la temporada de tormentas cuando se considera umbrales menores (ver Figura 4.6 y 4.7), fenómeno que explica la variabilidad de los volúmenes de deshielos y sus máximos asociados a una mayor acumulación durante invierno. En la comparación de los gráficos, se vislumbra que un umbral de 0.9 resulta poco adecuado y no representa la misma tendencia de las demás figuras. Para este valor se asignan muchos puntos de cobertura nula a grandes crecidas, lo cual no es lógico.



Un resultado similar, en el que la tendencia es hacia un modelo exponencial, se obtiene en las cuencas

del río Juncal y el río Volcán. Por el contrario, en las cuencas del río Putaendo y del río Alicahue, la tendencia es lineal para los diferentes umbrales, mientras en la cuenca del estero Pocuro, el resultado no permite ajustar un modelo de la misma naturaleza. Los resultados obtenidos en la cuenca del río Alicahue en Collihuay, se muestran desde la Figura 4.14 hasta la Figura 4.16.



En la cuenca del río Alicahue se aprecia una tendencia constante para los diferentes umbrales, en el que existe un conjunto importante de valores que tienen asignado 0% de cubierta nival. En este caso el modelo lineal explica un 73% de la desviación observada de los datos.

Desde la Tabla 4.11 hasta la Tabla 4.16 se muestra el resumen de los resultados del ajuste de un modelo lineal para cada cuenca. Un aspecto interesante de resaltar respecto de la información ingresada para el estudio de los modelos lineales, son los pares de puntos considerados que corresponden al total de imágenes menos las eliminadas. Sobre la cuenca del río Alicahue, se observan que las mejores correlaciones se consiguen para valores umbrales de NDSI de 0.7 y 0.6. Para los umbrales restantes la correlación es menor. Sobre las demás cuencas se aplicó la misma regla, es decir, se mantuvo como período de desfase único aquel definido para NDSI de 0.7 y 0.6.

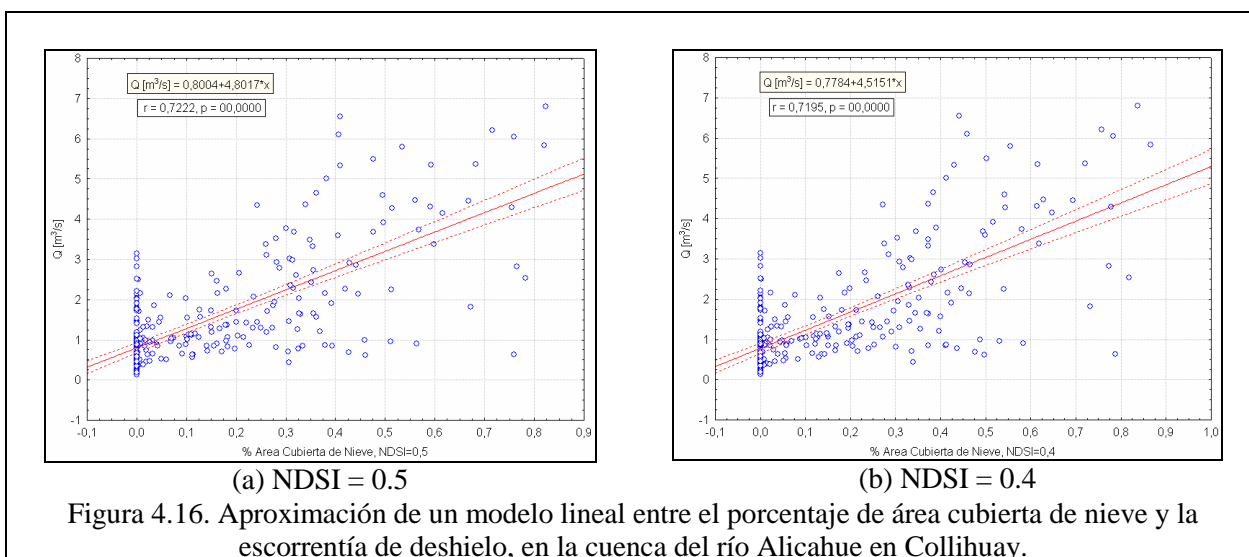


Tabla 4.11. Resultados de la aplicación de un modelo de correlación lineal entre las variables, caudal de deshielo y porcentaje de área cubierta de nieve, en la cuenca del río Alicahue.

NDSI	Períodos de desfase	Días	Información total	r^2	r	p valor
0.9	11	88	304	0.35	0.59	< 0.001
0.8	11	88	305	0.52	0.72	< 0.001
0.7	11	88	308	0.53	0.73	< 0.001
0.6	11	88	309	0.53	0.73	< 0.001
0.5	11	88	309	0.52	0.72	< 0.001
0.4	11	88	309	0.52	0.72	< 0.001

Tabla 4.12. Resultados de la aplicación de un modelo de correlación lineal entre las variables, caudal de deshielo y porcentaje de área cubierta de nieve, en la cuenca del río Putaendo.

NDSI	Períodos de desfase	Días	Información total	r^2	r	p valor
0.9	14	112	292	0.29	0.54	< 0.001
0.8	14	112	292	0.50	0.71	< 0.001
0.7	14	112	292	0.55	0.74	< 0.001
0.6	14	112	295	0.53	0.73	< 0.001
0.5	14	112	296	0.53	0.73	< 0.001
0.4	14	112	296	0.52	0.72	< 0.001

Tabla 4.13. Resultados de la aplicación de un modelo de correlación lineal entre las variables, caudal de deshielo y porcentaje de área cubierta de nieve, en la cuenca del río Juncal.

NDSI	Períodos de desfase	Días	Información total	r^2	r	p valor
0.9	19	152	268	0.34	0.59	< 0.001
0.8	19	152	268	0.66	0.81	< 0.001
0.7	19	152	268	0.70	0.83	< 0.001
0.6	19	152	269	0.67	0.82	< 0.001
0.5	19	152	269	0.63	0.80	< 0.001
0.4	19	152	269	0.61	0.78	< 0.001

Tabla 4.14. Resultados de la aplicación de un modelo de correlación lineal entre las variables, caudal de deshielo y porcentaje de área cubierta de nieve, en la cuenca del estero Pocuro.

NDSI	Períodos de desfase	Días	Información total	r^2	r	p valor
0,9	15	120	295	0,02	0,15	0,010
0,8	15	120	295	0,05	0,21	< 0,001
0,7	15	120	295	0,05	0,23	< 0,001
0,6	15	120	295	0,05	0,22	< 0,001
0,5	15	120	295	0,05	0,22	< 0,001
0,4	15	120	295	0,05	0,22	< 0,001

Tabla 4.15. Resultados de la aplicación de un modelo de correlación lineal entre las variables, caudal de deshielo y porcentaje de área cubierta de nieve, en la cuenca del río Volcán.


NDSI	Períodos de desfase	Días	Información total	r^2	r	p valor
0.9	17	136	278	0.31	0.56	< 0.001
0.8	17	136	278	0.51	0.71	< 0.001
0.7	17	136	279	0.55	0.74	< 0.001
0.6	17	136	280	0.52	0.72	< 0.001
0.5	17	136	319	0.50	0.71	< 0.001
0.4	17	136	319	0.49	0.70	< 0.001

Tabla 4.16. Resultados de la aplicación de un modelo de correlación lineal entre las variables, caudal de deshielo y porcentaje de área cubierta de nieve, en la cuenca del río Maipo.


NDSI	Períodos de desfase	Días	Información total	r^2	r	p valor
0.9	17	136	274	0.38	0.62	< 0.001
0.8	17	136	274	0.54	0.73	< 0.001
0.7	17	136	276	0.56	0.75	< 0.001
0.6	17	136	278	0.53	0.73	< 0.001
0.5	17	136	280	0.50	0.71	< 0.001
0.4	17	136	280	0.48	0.69	< 0.001

En general, para las cuencas estudiadas, la mejor correlación se obtiene para un umbral NDSI igual a 0.7, lo cual sugiere a este valor como el más apropiado en la región de estudio. La explicación de la varianza de un modelo lineal para las series de datos es mayor al 70%, con un valor de confianza $p < 0.001$, lo cual verifica la existencia de una relación entre las variables y atestigua una relación lineal entre ellas. Se advierte que sobre la cuenca del estero Pocuro, la relación lineal no es tan válida, resultado que era esperable por la naturaleza de la cuenca (fuerte componente pluvial en el régimen de escorrentía).

Además, sobre la cuenca del río Juncal, se podría pensar que la relación lineal es aún más evidente con un coeficiente de correlación mayor a 0.8, sin embargo, como se discutió anteriormente, la tendencia en las cuencas de mayor altura es hacia una relación exponencial. Para representar mejor la tendencia observada en los puntos, se procedió a aplicar el logaritmo natural sobre los datos de caudales de deshielo. Para contrastar los resultados, se muestran las gráficas de correlaciones lineales en la cuenca del río Juncal, considerando los valores de caudales sin alteración y en logaritmo natural.




(a) Sin alteración

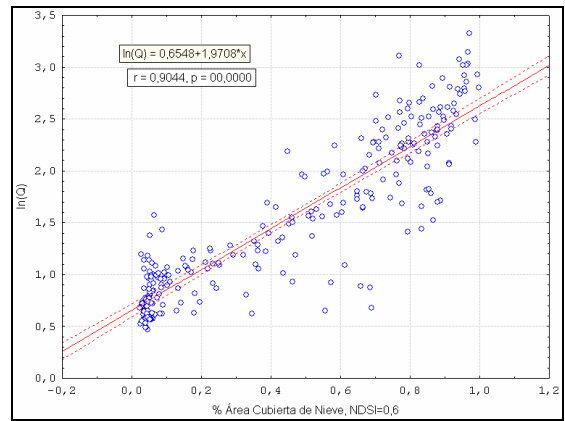


(b) ln(Q)

Figura 4.17. Aproximación de un modelo lineal entre el porcentaje de área cubierta de nieve y la escorrentía de deshielo, en la cuenca del río Juncal en Juncal, NDSI =0.7.




(a) Sin alteración




(b) ln(Q)

Figura 4.18. Aproximación de un modelo lineal entre el porcentaje de área cubierta de nieve y la escorrentía de deshielo, en la cuenca del río Juncal en Juncal, NDSI =0.6.




(a) Sin alteración



(b) ln(Q)

Figura 4.19. Aproximación de un modelo lineal entre el porcentaje de área cubierta de nieve y la escorrentía de deshielo, en la cuenca del río Juncal en Juncal, NDSI =0.5.



De las figuras anteriores, se destaca que las correlaciones son más altas considerando umbrales de 0.6 y 0.7, independiente de la transformación de la información de caudales de deshielo. Es importante hacer notar que la transformación de la información busca resaltar aquellos aspectos de mayor relevancia en la serie, lo que se observa mediante la generación de dos grupos de nubes de puntos más concentradas en los extremos de los gráficos de correlación. El resumen de los resultados para las cuencas de mayor altitud se muestra en las Tablas 4.18, 4.19 y 4.20.

Tabla 4.18. Resultados de la aplicación de un modelo de correlación lineal entre las variables, logaritmo natural del caudal de deshielo y porcentaje de área cubierta de nieve, en la cuenca del río Juncal.

NDSI	Períodos de desfase	Días	Información total	r^2	r	p valor
0.9	19	152	268	0.39	0.63	< 0.001
0.8	19	152	268	0.75	0.86	< 0.001
0.7	19	152	268	0.82	0.91	< 0.001
0.6	19	152	269	0.82	0.90	< 0.001
0.5	19	152	269	0.80	0.89	< 0.001
0.4	19	152	269	0.79	0.89	< 0.001

Tabla 4.19. Resultados de la aplicación de un modelo de correlación lineal entre las variables, logaritmo natural del caudal de deshielo y porcentaje de área cubierta de nieve, en la cuenca del río Volcán.

NDSI	Períodos de desfase	Días	Información total	r^2	r	p valor
0.9	17	136	278	0.35	0.59	< 0.001
0.8	17	136	278	0.59	0.77	< 0.001
0.7	17	136	279	0.69	0.83	< 0.001
0.6	17	136	280	0.70	0.84	< 0.001
0.5	17	136	319	0.70	0.83	< 0.001
0.4	17	136	319	0.69	0.83	< 0.001

La transformación de los datos de caudales permite reconocer una relación lineal más clara, consiguiendo valores del coeficiente de correlación por sobre 0.8, e incluso de 0.9 para el caso de la cuenca del río Juncal.

Tabla 4.20. Resultados de la aplicación de un modelo de correlación lineal entre las variables, logaritmo natural del caudal de deshielo y porcentaje de área cubierta de nieve, en la cuenca del río Maipo.

NDSI	Períodos de desfase	Días	Información total	r^2	r	p valor
0.9	17	136	274	0.42	0.65	< 0.001
0.8	17	136	274	0.61	0.78	< 0.001
0.7	17	136	276	0.66	0.81	< 0.001
0.6	17	136	278	0.65	0.81	< 0.001
0.5	17	136	280	0.63	0.79	< 0.001
0.4	17	136	280	0.62	0.79	< 0.001

Finalmente, la explicación mediante modelos lineales y exponenciales resulta acertada a las series históricas de las variables estudiadas. Además, el conjunto de análisis permite definir un umbral NDSI de 0.7 como el más idóneo para la comparación de series, el cual es mayor a 0.4. Esto ayuda a corroborar el hecho de que al existir una menor influencia de la cobertura vegetal, el umbral debe ser mayor.

Los resultados de la aplicación lineal entre las series de tiempo y de las correlaciones cruzadas, para cada cuenca, se encuentran en el Anexo Magnético.

4.2.4. Estudio de Transectas para la Búsqueda de Patrones de Comportamiento

Las imágenes ofrecen una amplia gama de información que puede ser analizada desde diferentes perspectivas. Considerando que se tiene una serie temporal de éstas, es casi intuitiva la búsqueda de patrones de comportamiento o conjunto de rasgos esenciales, que permitan entender algunas relaciones para consigo misma (componentes principales) o con otras variables.

Para realizar un seguimiento a la cobertura de nieves en una región determinada, una alternativa es mediante un estudio de áreas como el que se discutió en el punto anterior. Otra alternativa es utilizar un corte de cada imagen que permita generar un mosaico histórico, representación similar a los anillos que forman la corteza en un árbol o a un testigo de hielo utilizado para descifrar relaciones paleoclimáticas. De esta manera, una transecta obtenida de cada imagen, correspondiente a la misma ubicación geográfica, y ordenada históricamente tendrá el mismo sentido que un “testigo”, y permitirá entender la evolución del fenómeno de acumulación y derretimiento de la nieve.

En el presente estudio de transectas, se utilizaron las imágenes con filtro NDSI de manera de distinguir las zonas cubiertas de nieve. Sólo se definieron transectas orientadas de poniente a oriente en la búsqueda de una pendiente de terreno positiva que permitiese distinguir variabilidad de acumulación de nieve con la altura, debido que a una mayor altura los procesos de derretimiento de la nieve se desarrollan más lentamente. En la Figura 4.21 se muestra la evolución anual de una transecta de la cuenca del río Volcán. La escala de valores indica en color rojo la existencia de nieve. Para valores entre 0.7 y 0.4 la caracterización de la nieve puede entenderse como pobre o de bajo albedo. Valores menores a 0.4 indican la existencia de cubierta desprovista de nieve (Dozier, 1989).

En la evolución de las transectas se distingue el período de acumulación, que se desarrolla desde abril hasta junio, luego un período de continuidad definido por un derretimiento lento alternado con acumulaciones, que se desarrolla desde julio hasta septiembre, y finalmente el período de derretimiento sostenido desde octubre hasta enero.

El período de continuidad concuerda con la época en que las temperaturas son más bajas del año y esta característica se puede explicar mediante el concepto de línea de nieve que constituye una restricción a la existencia de nieve a una determinada altura.

La evolución de las transectas muestra además la interferencia atmosférica de manera notoria, que se distingue por transectas de color amarillo entre dos de color rojo o apariencia normal. Esto último ratifica la regla heurística de eliminación de imágenes cuando éstas alteran la información de la serie en un continuo. Además, se avala la naturaleza del proceso como un fenómeno de cambios graduales en el tiempo. Durante el período de derretimiento acelerado la discontinuidad no existe y la interferencia es nula.

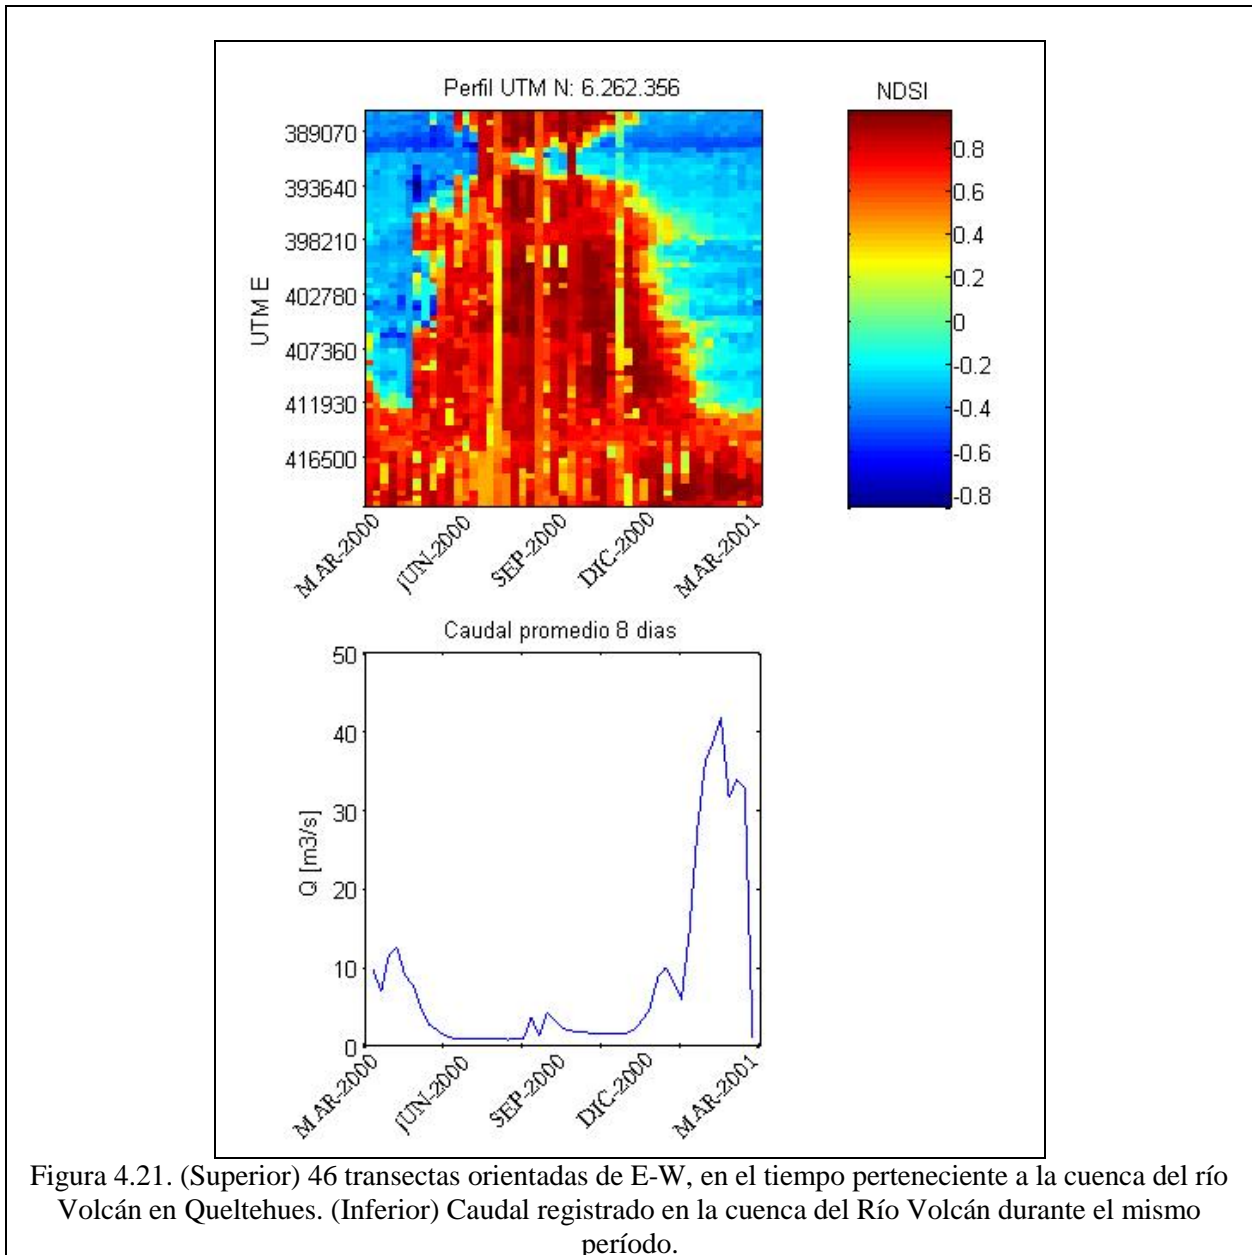


Figura 4.21. (Superior) 46 transectas orientadas de E-W, en el tiempo perteneciente a la cuenca del río Volcán en Queltehués. (Inferior) Caudal registrado en la cuenca del Río Volcán durante el mismo período.

Al comparar la evolución temporal de una transecta con el caudal se vislumbra, nuevamente, la relación entre la cobertura y la escorrentía de deshielo. El estudio de transectas utilizó 46 imágenes para definir un registro anual. Al ampliar este análisis a diferentes años, los resultados son reveladores, donde se observa claramente la variabilidad de acumulación de nieve año a año al igual como una lengua glaciar. Un ejemplo de esto se muestra en las Figuras 4.22, 4.23 y 4.24. En las siguientes figuras, la flecha en color rojo muestra la ubicación de la transecta escogida.

Se observa que durante el período de estudio, la variabilidad del manto observada mediante una transecta sigue la misma relación del manto completo en la región de estudio, siendo apreciable aquellos años con menor y mayor nivel de acumulación. Además, la disposición E-W de las transectas permite introducir de manera indirecta la topografía de la región, explicando la existencia continua de nieve sobre aquellas cumbres más altas y el derretimiento más intenso en regiones más bajas.

Este tipo de evaluaciones sobre imágenes en serie, resulta ser de gran utilidad pues permite apreciar el fenómeno de manera simplificada.

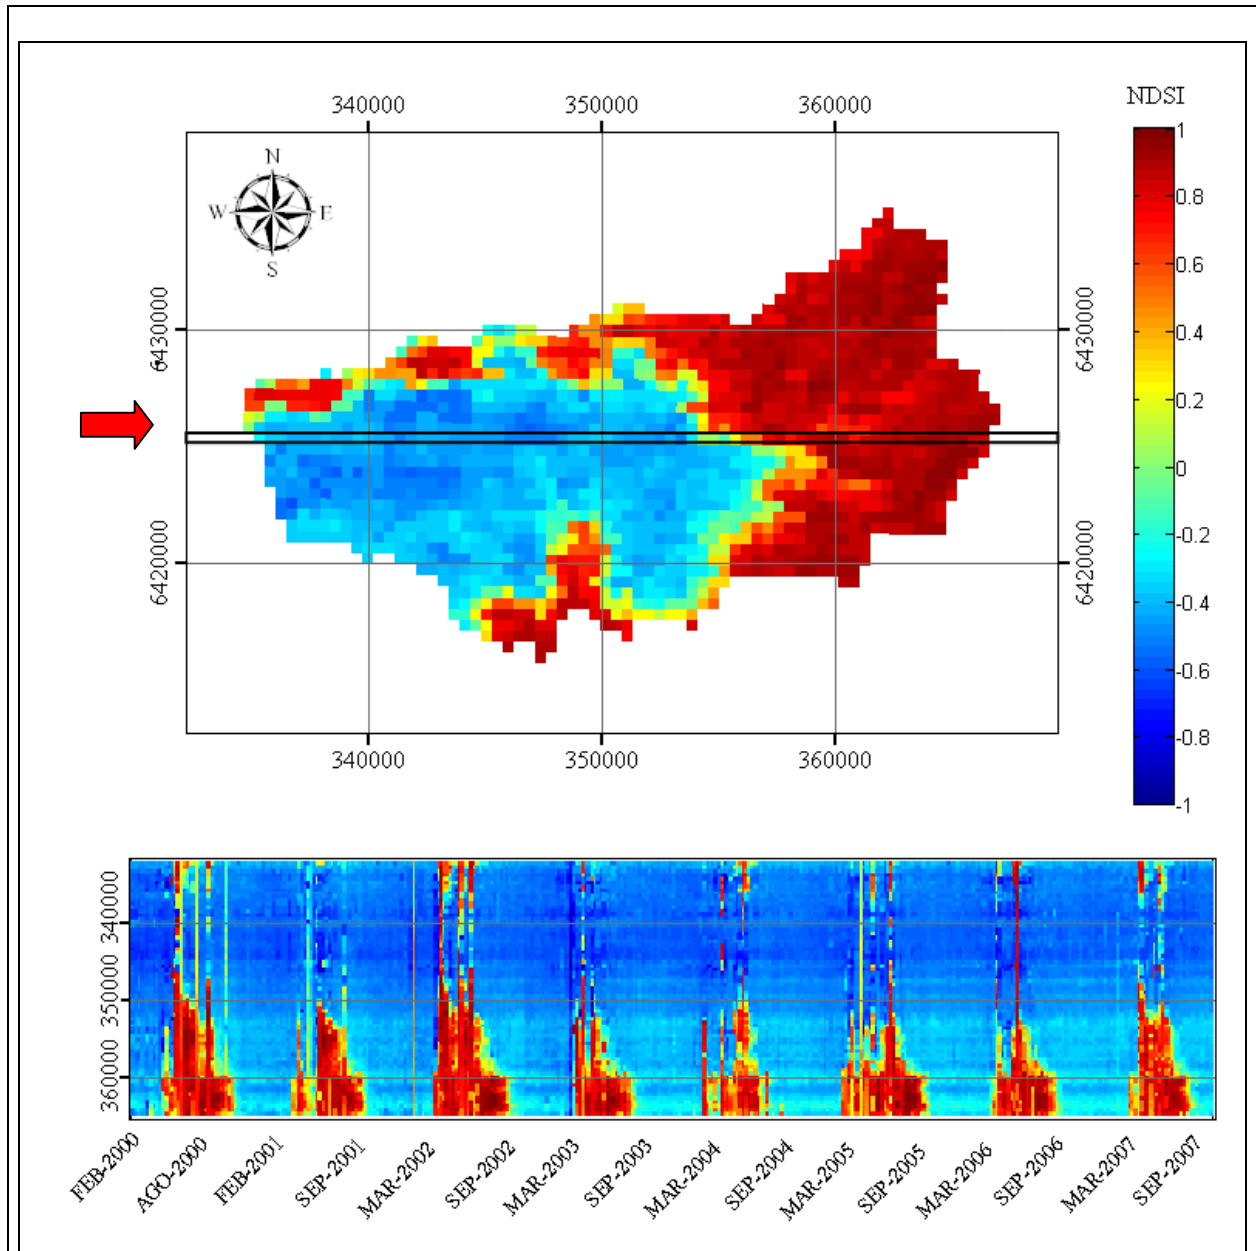


Figura 4.22. (Superior) Imagen de la cuenca del río Alichahue en Collihuay con aplicación del filtro NDSI, correspondiente al 24 de Octubre del año 2000. (Inferior) Mapa de transectas orientadas de E-O en el tiempo, perteneciente a la cuenca del río Alichahue.

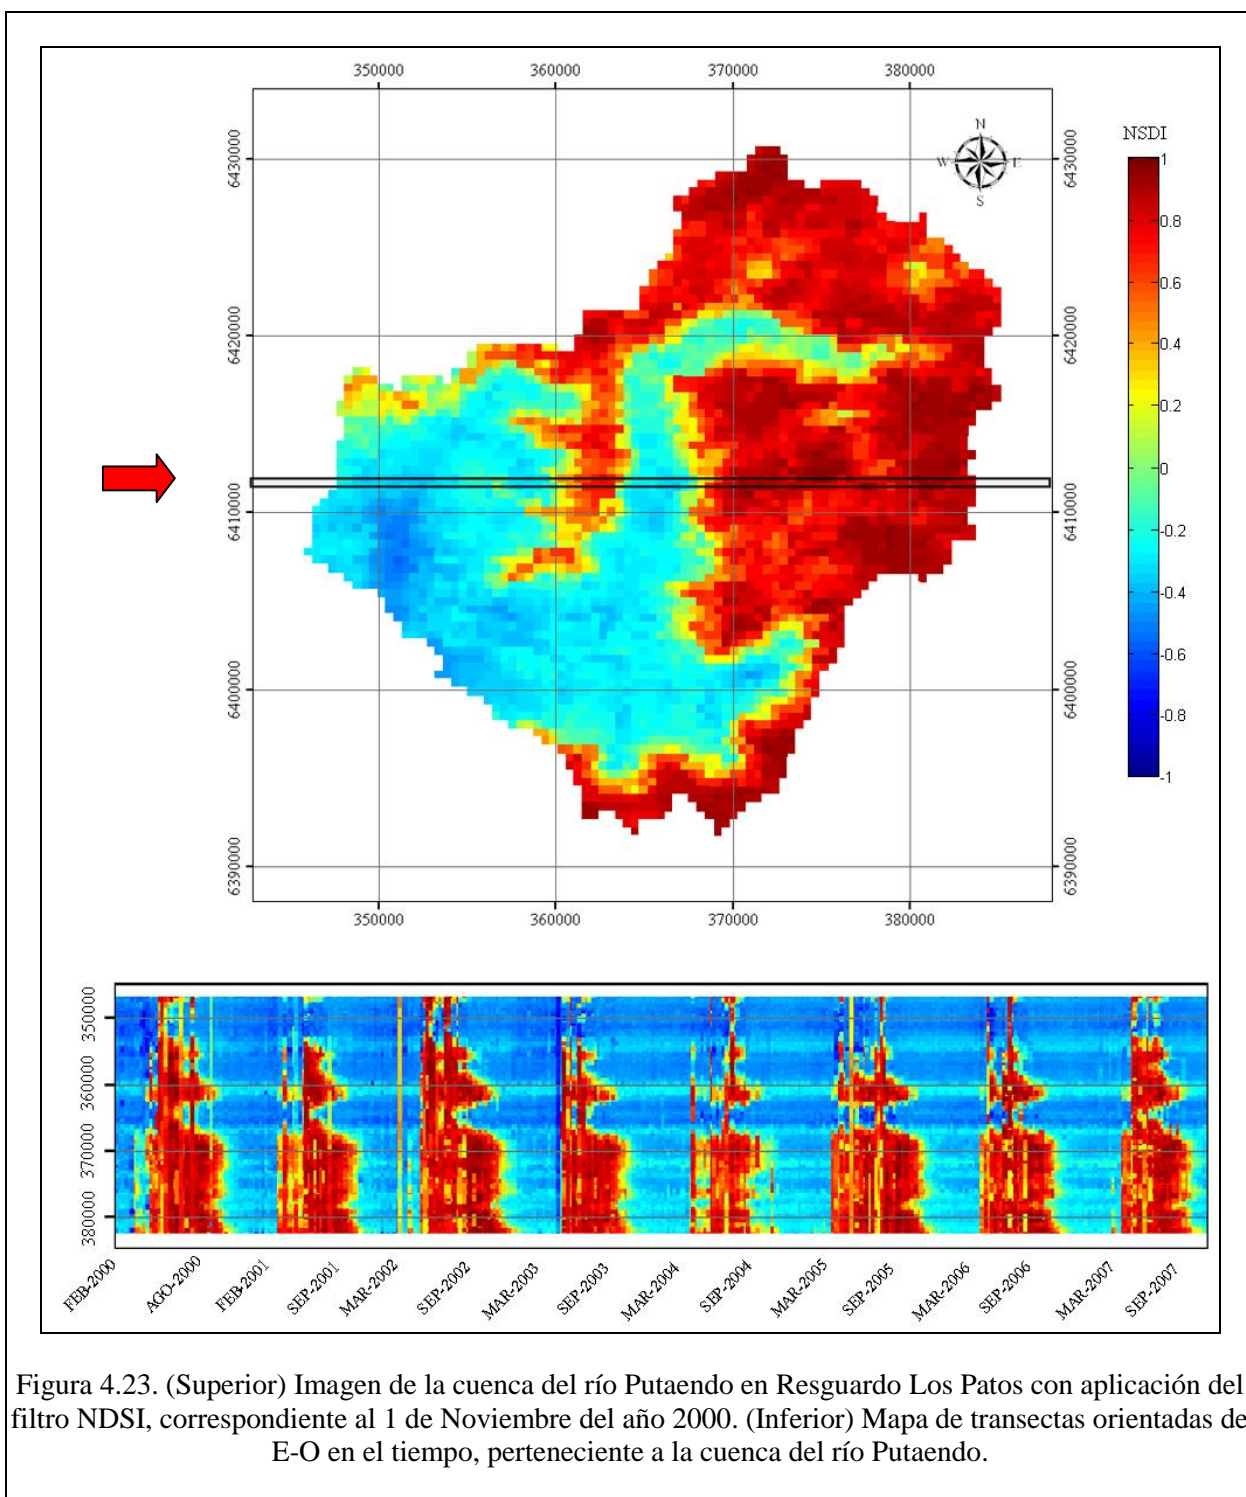


Figura 4.23. (Superior) Imagen de la cuenca del río Putaendo en Resguardo Los Patos con aplicación del filtro NDSI, correspondiente al 1 de Noviembre del año 2000. (Inferior) Mapa de transectas orientadas de E-O en el tiempo, perteneciente a la cuenca del río Putaendo.

Desde otro punto de vista, las transectas pueden ser entendidas como un conjunto de series de tiempo dependientes de la geomorfología del terreno. En la definición de información apropiada para la modelación de la escorrentía de deshielo mediante redes neuronales, resulta conveniente el uso de variadas series de tiempo que incluyan información de fenómenos significativos en la dinámica del manto.

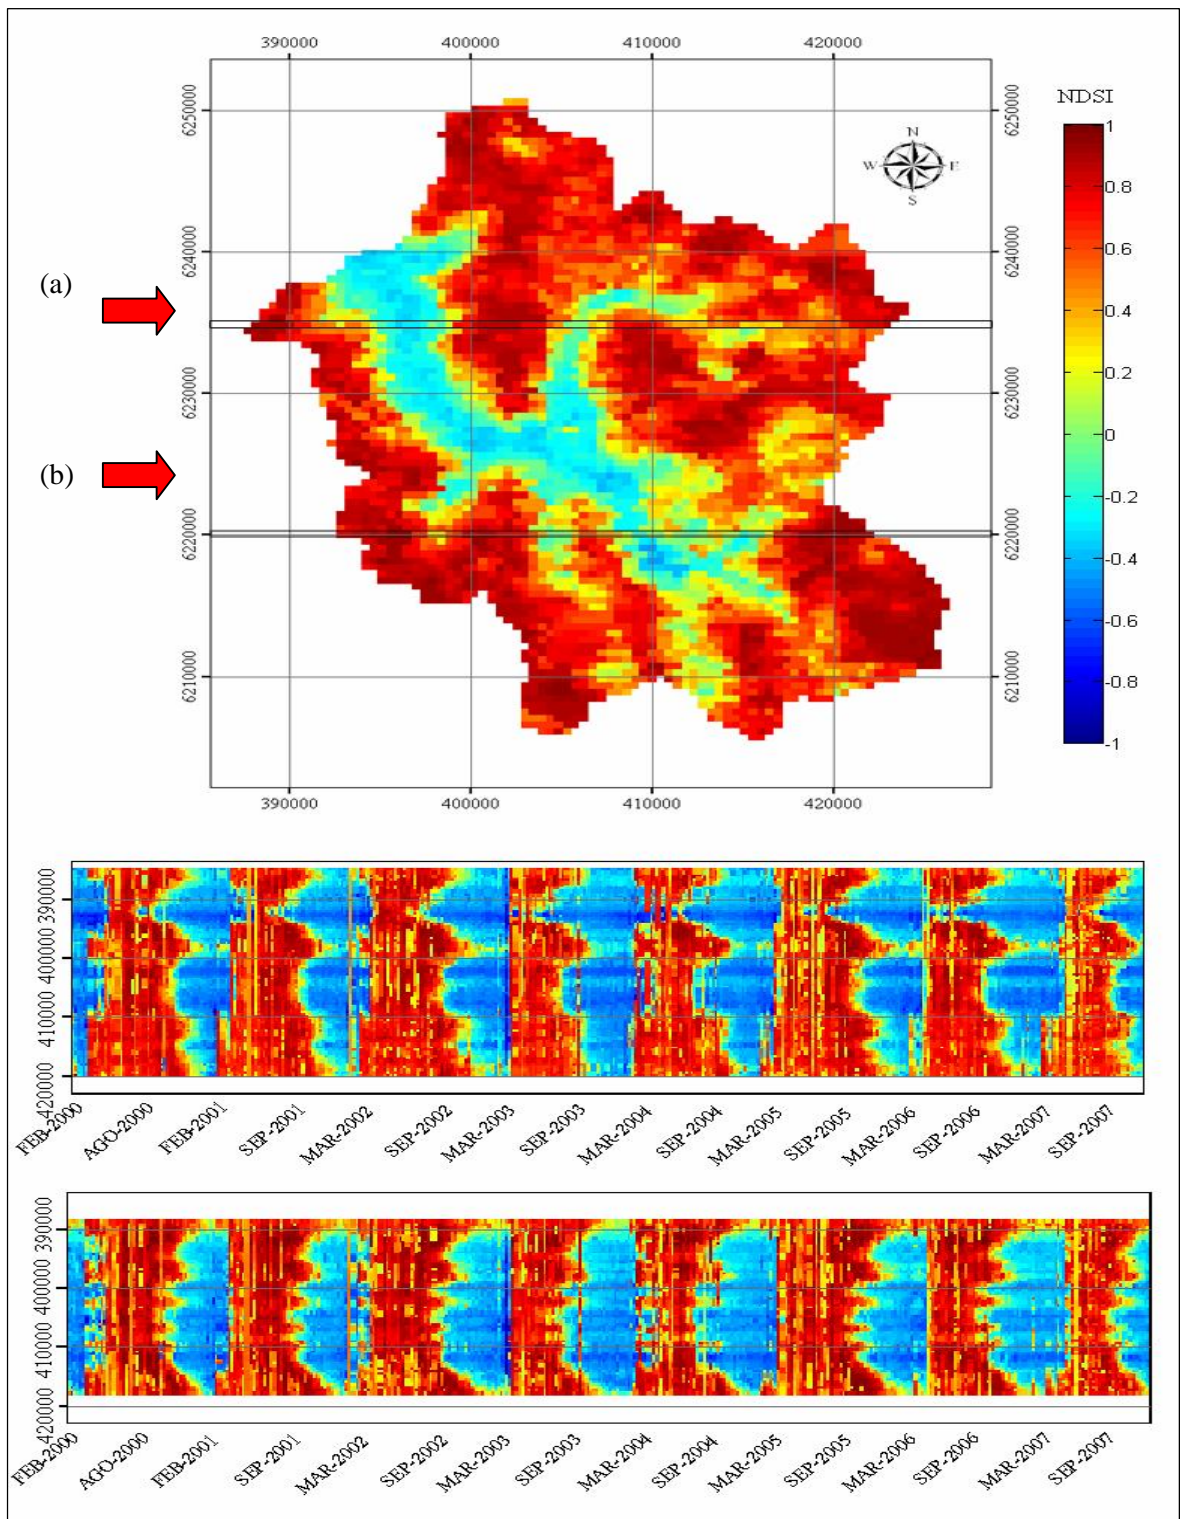


Figura 4.24. (Superior) Imagen de la cuenca del río Maipo en Las Hualtatas con aplicación del filtro NDSI, correspondiente al 24 de Octubre del año 2000. (Inferior) Mapa de transectas orientadas de E-O en el tiempo, perteneciente a la cuenca del río Maipo.

4.2.5. Relación entre Cobertura de Nieve y Temperatura de Altura

Existen dos aproximaciones básicas para modelar el comportamiento de la nieve: la solución por balance de energía y la de índice de temperatura. La solución por balance de energía se obtiene de un modelo de base física que incorpora en sus ecuaciones factores tales como radiación solar, viento, y radiación de onda larga. El segundo método básico, llamado la solución del índice de la temperatura, es un planteamiento más simplificado, en el que la temperatura del aire se considera un índice representativo de todas las fuentes de energía.

La relación por índice de temperatura es de tipo estadística, que engloba todos los procesos de calor en el gradiente de temperatura entre la atmósfera y la superficie de la nieve, y es aplicable a zonas extensas e inclusive a la totalidad de una cuenca. Esta solución es recomendable cuando no se dispone de información meteorológica robusta que permita estimar las componentes de calor, o cuando no se desea obtener el comportamiento detallado del manto. La relación básica por índice de temperatura permite determinar el derretimiento ocurrido (en milímetros) durante un instante de tiempo, que estará asociado a la escala temporal de la temperatura (Ecuación 4.1).

$$\text{Derret} = C_m \cdot (T_a - T_b) \text{ [mm]} \quad [4.1]$$

El coeficiente tasa de derretimiento (C_m) típicamente varía entre los 1,8 y 3,7 [mm/°C] (Valck *et al.*, 2004). La temperatura del aire (T_a) que se utiliza, depende de la aplicación del método y del tamaño de la cuenca involucrada. Para cuencas grandes comúnmente se utilizan los valores extremos de temperatura, utilizando generalmente la temperatura máxima ya que refleja mejor la nubosidad diaria. La temperatura base (T_b) es la temperatura de referencia de la superficie de la nieve, valor en torno a los 0 [°C], considerando típicamente este valor como representativo.

Ante la necesidad de entender la variabilidad de la temperatura y su relación con la evolución del manto, se estimó conveniente aplicar la misma metodología empleada en el punto 4.2.1 y 4.2.2, sobre una de las cuencas de mayor altitud.

La escasa información de temperatura en la alta cordillera de la región de estudio, es obtenida de la estación meteorológica Embalse El Yeso, ubicada en las cercanías del embalse del mismo nombre.

Tabla 4.21. Ubicación Estación Embalse El Yeso.


Nombre Estación	Coordenadas		Altitud [msnm]
	Lat. S	Lon. W	
Embalse El Yeso	33°40'	70°05'	2475

Fuente: Dirección General de Aguas.

De las cuencas estudiadas, la más cercana corresponde a la cuenca del río Volcán, por lo que sólo se realizó el análisis considerando dicha cuenca. La comparación de las series de cubierta de nieve y temperatura máximas y mínimas se muestra en la Figura 4.25. Sólo se utilizó la serie de porcentaje de cubierta de nieve resultante de aplicar un umbral NDSI de 0.7.

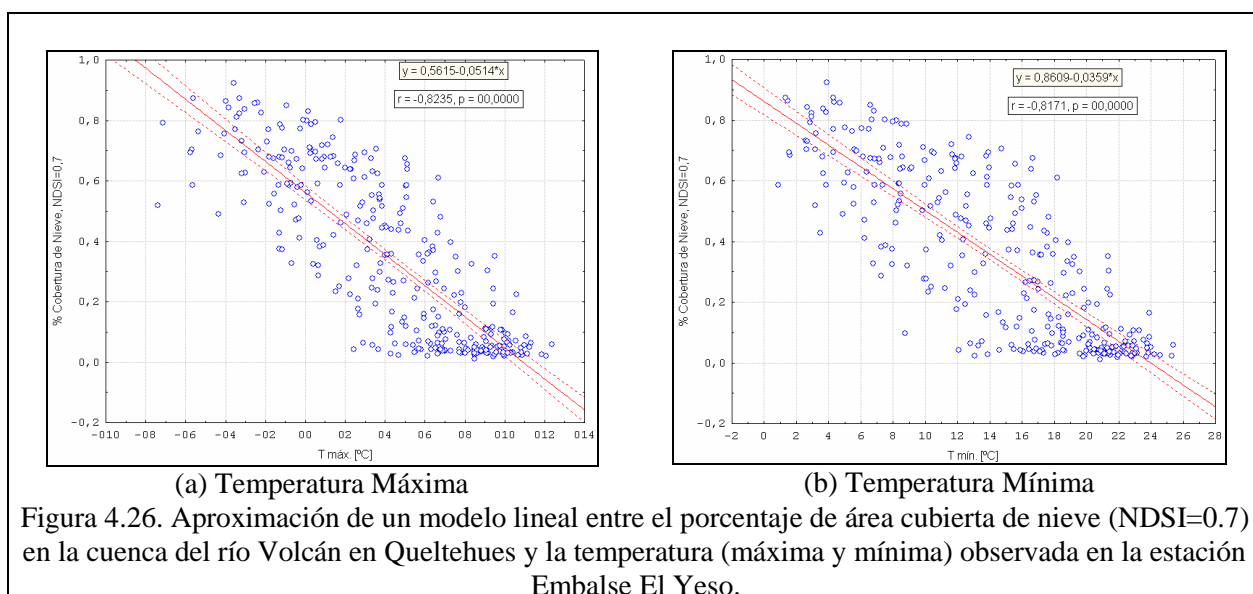
El registro de temperaturas es continuo durante el período 2000-2007, sin embargo, en la Figura 4.25, se eliminaron los registros correspondientes a aquellas imágenes con alta interferencia atmosférica, proceso descrito en el punto 4.2.2. De esta manera, el registro resultante consta de 311 registros cada 8 días.

En relación a la series de temperaturas, se tiene que la media es de 8.9° C, con 3,9° C promedio de temperatura mínima y 13.8° C promedio de temperatura máxima. Además, se observan variaciones estacionales uniformes para las máximas y mínimas, alcanzando máximos y mínimos anuales en torno a los 23° C y -3° C, respectivamente. Respecto de la diferencia entre temperaturas máximas y mínimas, ésta también se mantiene estacionalmente uniforme, con una mayor amplitud durante la temporada estival que durante la temporada invernal.



Al comparar la variabilidad de las temperaturas máximas y mínimas con el porcentaje de área cubierta durante el período de tormentas o acumulación de nieve, se distingue una clara relación de proporcionalidad inversa entre las variables. Este fenómeno es de gran interés, pues permite relacionar la temperatura con la intensidad de nieve caída durante la tormenta.

Los resultados de la aplicación de un modelo lineal entre temperaturas máximas y mínimas con el porcentaje de cubierta de nieve son similares, con una correlación de -0.82 ($r^2 = 0.67$), lo que demuestra la relación inversa de las variables. Los resultados se aprecian en la Figura 4.26.



Al aceptar la relación lineal entre la temperatura y la cobertura de nieve observada en la Figura 4.26 y, teniendo en cuenta lo obtenido en el punto 4.2.2, que una relación aceptable entre caudales observados y porcentaje de área cubierta es del tipo exponencial, es posible relacionar el caudal observado con la temperatura registrada, dando como resultado una relación no lineal. Esto discrepa con lo indicado por la Ecuación 4.1.

Es posible que la componente altitudinal influya de manera importante en los resultados, acelerando los procesos de derretimiento que conllevan a los elevados volúmenes de deshielo. Esto demuestra nuevamente lo inapropiado que resulta el utilizar relaciones generadas en otras latitudes, sin ser evaluadas en el país.

En la Figura 4.27, se comparan las variaciones de temperaturas máximas y mínimas con el caudal observado en la cuenca del río Volcán. Las escalas para la temperatura y el caudal poseen la misma longitud (70 unidades). Al distinguir el período de la crecida de deshielo, se aprecia que las tasas de incremento del caudal y las temperaturas no son iguales. Esto permite aclarar la existencia de una relación no lineal de las variables durante el período de aumento de la escorrentía.




Figura 4.27. Temperatura mínima y máxima (promedio cada 8 días) observada en la estación Embalse El Yeso, y el caudal observado (promedio cada 8 días) en la cuenca del río Volcán en Queltehués.

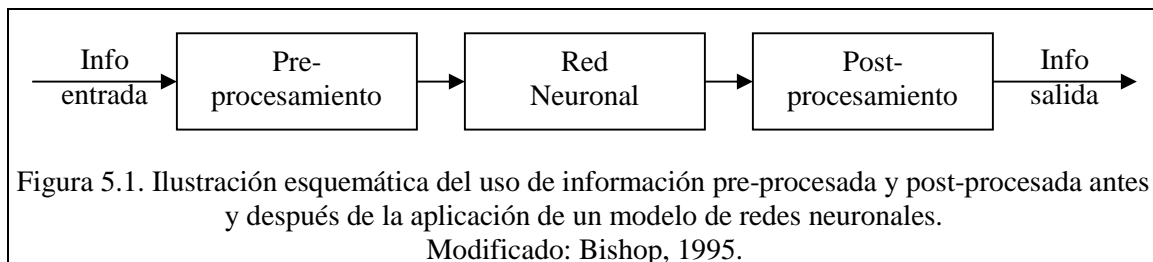
CAPÍTULO V ESTRUCTURA DEL MODELO DE SIMULACIÓN DE REDES NEURONALES

5.1. PRE-PROCESAMIENTO Y POST-PROCESAMIENTO DE LA INFORMACIÓN

Existen dos componentes básicas en el análisis de las series de tiempo: (i) la identificación de la naturaleza del fenómeno representada por la secuencia de observaciones y, (ii) la predicción de valores futuros de la serie. Ambos propósitos requieren que se identifique el patrón de comportamiento de la variable, para lo cual resulta de gran utilidad la extracción de características del fenómeno en estudio.

Las redes neuronales artificiales responden a estas condiciones y limitantes del problema. Este tipo de herramientas provenientes de la inteligencia artificial, surgen como una alternativa capaz de entender el comportamiento de algunos fenómenos sin necesidad de saber su origen natural o artificial. Dentro de sus aplicaciones más exitosas se destaca la predicción, para lo cual se emplean las redes neuronales recurrentes que permiten evaluar fenómenos temporales mediante la incorporación de información autorregresiva y de carácter independiente.

En muchas aplicaciones prácticas, el preprocesamiento de la información es uno de los factores más significativos en la determinación de la respuesta final del sistema. La aplicación de un modelo de redes neuronales no es la excepción a esta regla (Bishop, 1995). En los casos más simples, el pre-procesamiento puede implicar la linealización de los datos de entrada, mientras que en casos más complejos, pueden significar la reducción en la dimensión de la información de entrada. Similarmente, la respuesta de la red puede ser post-procesada para alcanzar los valores deseados. En la Figura 5.1 se muestra un esquema que explica lo planteado.



El preprocesamiento y post-procesamiento pueden consistir en simples transformaciones como por ejemplo la estandarización de la señal. Otra manera simple de aplicar el pre-procesamiento consiste en la reducción en la dimensión de la información de entrada, lo cual se consigue seleccionando un conjunto de la información original, o combinando las variables iniciales de manera de aumentar el número de entradas a la red (Bishop, 1995).

La caracterización de la información desarrollada en el CAPÍTULO IV es un pilar fundamental para la modelación de la escorrentía pues, además de permitir una mejor comprensión del fenómeno estudiado, otorga un conocimiento más acabado acerca de la dimensión de la información disponible. Esto último puede ser entendido como una visualización previa de las opciones de preprocesamiento útiles en la modelación, como por ejemplo: la reducción en la dimensión de la información remota mediante la elección de un conjunto determinado de píxeles o la búsqueda de un factor para la estandarización de los caudales respecto de la información remota sujeta a valores entre -1 y 1, y entre 0 y 1 para el caso del área de cobertura.

En el presente capítulo se busca estructurar un modelo que permita modelar la escorrentía, mediante la selección de diferentes píxeles que entreguen información relevante acerca de la evolución del

manto. Esta búsqueda se enmarca en el desafío por la modelación de carácter semi-distribuido. El objetivo de este capítulo es mostrar una metodología para el empleo de modelos de redes neuronales como generadores de pronóstico, mediante el uso de registros fluviométricos e información remota seleccionada y preprocesada. A continuación se describe la estructura del modelo de pronóstico.

5.2. ESTRUCTURA GENERAL DEL MODELO

En la búsqueda de un modelo de pronóstico para la temporada de deshielo se seleccionó un tipo de herramienta capaz de reconocer patrones de comportamiento sobre series temporales múltiples. Dentro de las alternativas existentes, existen aplicaciones que se enfocan en el estudio de las series de tiempo individuales como los modelos ARIMA (Autorregresive Moving Average) descritos por Box y Jenkins (1976), series de tiempo para 2 ó 3 variables como los modelos de Función de Transferencia, y múltiples series de tiempo como los modelos de Redes Neuronales Recurrentes.

Según lo indicado en el CAPÍTULO III, uno de los criterios de selección de las cuencas fue que el área de ésta fuese pequeña de manera de incluir todas las series temporales asociadas a cada píxel. De acuerdo a los alcances de la modelación, la búsqueda de un área pequeña permitiría la inclusión de todas las regiones muestreadas por los sensores remotos.

La información de entrada a las redes neuronales advierte una limitante asociada a la generalización del modelo, que está dada por la cantidad de neuronas versus el número de registros o casos que se tienen para el entrenamiento de la red. De esta forma, al tener sólo 359 registros satelitales que corresponde al número de casos disponibles, el número de neuronas de la red queda limitado a un 10% de esta información según reglas heurísticas, considerando además que se debe hacer una separación entre conjunto de entrenamiento, validación y prueba. Esta condición puede ser entendida como la búsqueda de la parsimonia del modelo, ya que cada neurona tendrá asociado un peso relativo que será ajustado en la etapa de entrenamiento. Los pesos de la red pueden ser entendidos como los parámetros del modelo.

Para ello, sobre cada cuenca se seleccionarán diferentes píxeles donde cada uno representará la evolución de la cobertura de nieve asociada a dicha región como una serie de tiempo. Esta información conformará la entrada o input al modelo. Para comprender la estructura general del modelo planteado, en la Figura 5.2 se muestra un esquema explicativo. La elección del conjunto de píxeles se hará de acuerdo a cuatro modalidades, que a continuación se explican.

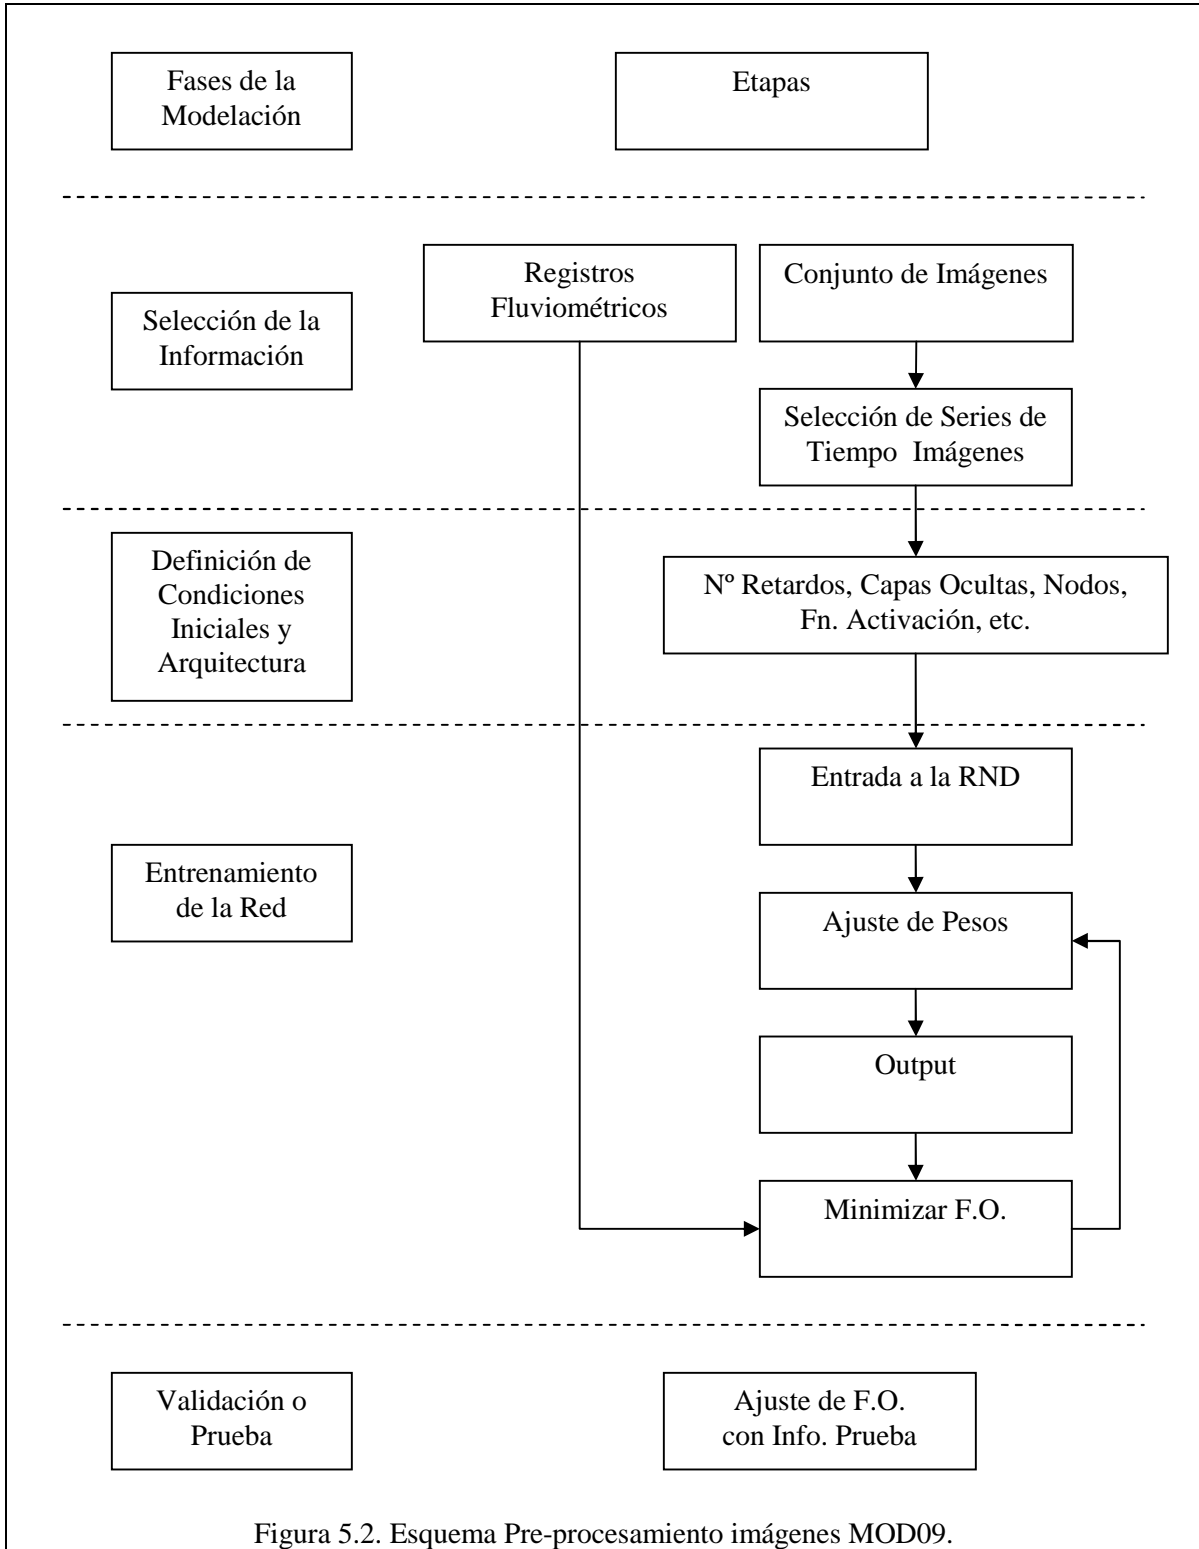


Figura 5.2. Esquema Pre-procesamiento imágenes MOD09.

5.3. CONFIGURACIONES PARA LA SELECCIÓN DE LA INFORMACIÓN

La información satelital puede ser abordada desde dos enfoques: (i) en su conjunto como un registro genérico de algún elemento como por ejemplo el porcentaje de cobertura nival o, (ii) de forma distribuida

donde cada píxel reconoce una característica puntual del elemento genérico. La mayor ventaja de este segundo enfoque es que permite asociar esta característica a una dimensión espacial. Si se captura la información para una misma región en diferentes períodos, es posible generar un registro en el que el elemento genérico tenga asociado la dimensión conjunta espacio-temporal, el cual posee una enorme potencialidad. Bajo esta condición, es imprescindible buscar aquellas regiones de la cuenca que sean relevantes para el seguimiento de los procesos de almacenamiento y derretimiento del manto, puesto que no es posible incluir todos los píxeles de la cuenca en la red. Sin embargo, esta búsqueda puede resultar bastante tediosa si se evalúa de forma independiente cada serie de tiempo por cada píxel. Una manera diferente de abordar este problema es mediante la selección de un conjunto de píxeles elegidos de acuerdo a ciertas características o de forma arbitraria, y evaluados a partir de la respuesta final o calidad en el pronóstico.

Cabe destacar que la selección de información se realizará sobre la base de aquella región que está delimitada por la cuenca característica, definida topográficamente, sin la inclusión de información que esté fuera de esta región. Para la selección del conjunto de zonas críticas o píxeles que representen la región de interés se definieron 4 modalidades de acuerdo a los siguientes criterios:

- azar,
- sistemático al azar según topografía,
- sistemático al azar según cobertura y,
- transecta central.

La selección aleatoria es una primera búsqueda del mejor conjunto. Al realizar una búsqueda sistemática al azar se busca elegir aquellos píxeles de forma aleatoria en una región con ciertas características definidas a priori, como puede ser algún rango de cotas en el caso de la topografía, o de acuerdo a la condiciones de acumulación en el caso según coberturas. En una cuarta modalidad se evaluarán píxeles de una transecta seleccionada de forma directa. A continuación se explica en detalle cada una.

5.3.1. Elección de Píxeles al Azar

La selección al azar se realizó sobre la base de una función generadora de números aleatorios en Matlab. En la Figura 5.3 se muestran 4 resultados de esta configuración aplicada en la cuenca del río Volcán. El número de series definidas a priori fueron 10.

Debido a que se busca encontrar aquellas series que entreguen información relevante del manto como lo es el inicio del período de derretimiento o la acumulación máxima del mismo, la selección al azar puede entregar resultados de variada calidad en relación a estas características, puesto que se puede estar eligiendo información concentrada en algún sector de la cuenca como puede ser a la salida o en algún extremo (Figura 5.3.a). Ante esta condición, un mayor número de series puede resultar conveniente para el entrenamiento de la red puesto que se tendrá más posibilidades de incluir información independiente que sea relevante.

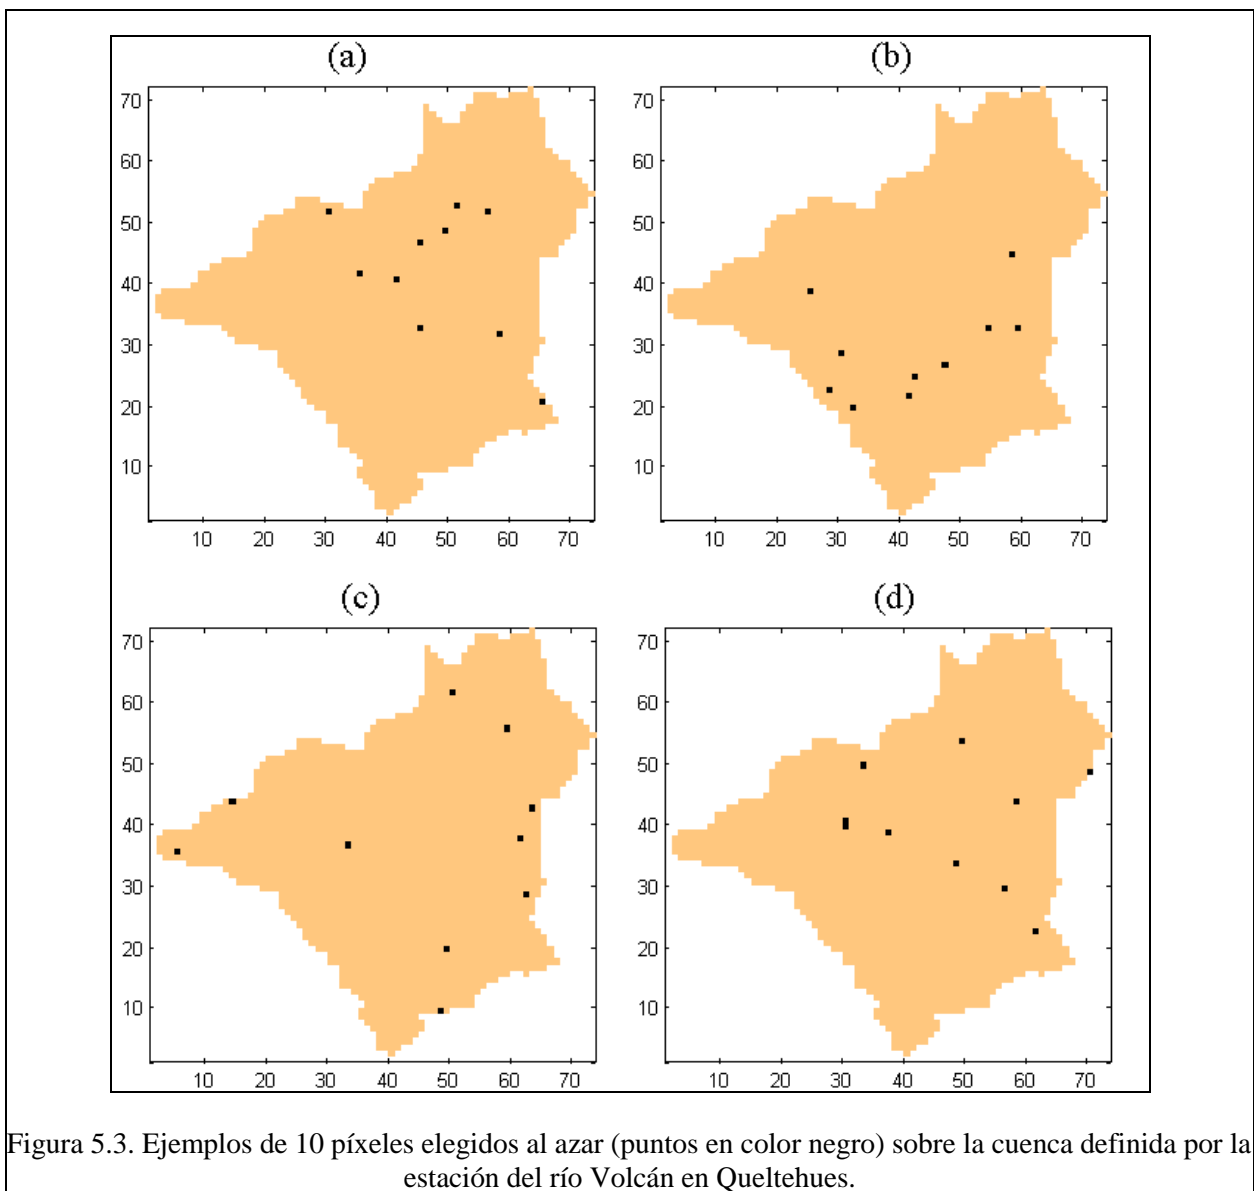


Figura 5.3. Ejemplos de 10 píxeles elegidos al azar (puntos en color negro) sobre la cuenca definida por la estación del río Volcán en Queltehués.

5.3.2. Elección de Píxeles Sistemático al Azar según Topografía

La búsqueda sistemática permite asociar la búsqueda aleatoria a una característica definida que permita encontrar aquellos elementos claves de una manera guiada. Si bien, en el CAPÍTULO IV no se realizó ningún análisis en relación a la variabilidad del manto según la altitud, en el CAPÍTULO II se señaló que las condiciones fisiográficas del terreno definían la dinámica del manto en torno a los procesos de acumulación y derretimiento. Es por este motivo que uno de los criterios razonables para la discriminación de los píxeles es de acuerdo a la topografía de la región, en la que la selección aleatoria estará condicionada a un rango de cotas definidas previamente. En la Figura 5.4 se muestran 4 ejemplos de este tipo de selección.

La discriminación de los píxeles se realizó en base a la altura mínima y máxima de la cuenca, de acuerdo a la siguiente pauta definida arbitrariamente:

- la diferencia entre la altura máxima y mínima se divide en 3 partes iguales, lo que permite definir 3 rangos de cotas: mínimo, medio y superior;

- del total de píxeles a encontrar, al menos 1 píxel representará al rango mínimo;
- una mitad de los píxeles restantes provendrán del rango medio y;
- la mitad restante provendrá del rango superior.

La pauta de selección según topografía puede resultar inapropiada para algunas regiones, sin embargo, como primera aproximación permite obtener como resultado una distribución espacial más homogénea de los píxeles sobre la cuenca. Esto último se aprecia en la Figura 5.4, en la que se advierte una mejor distribución de los píxeles que la conseguida con la selección al azar.

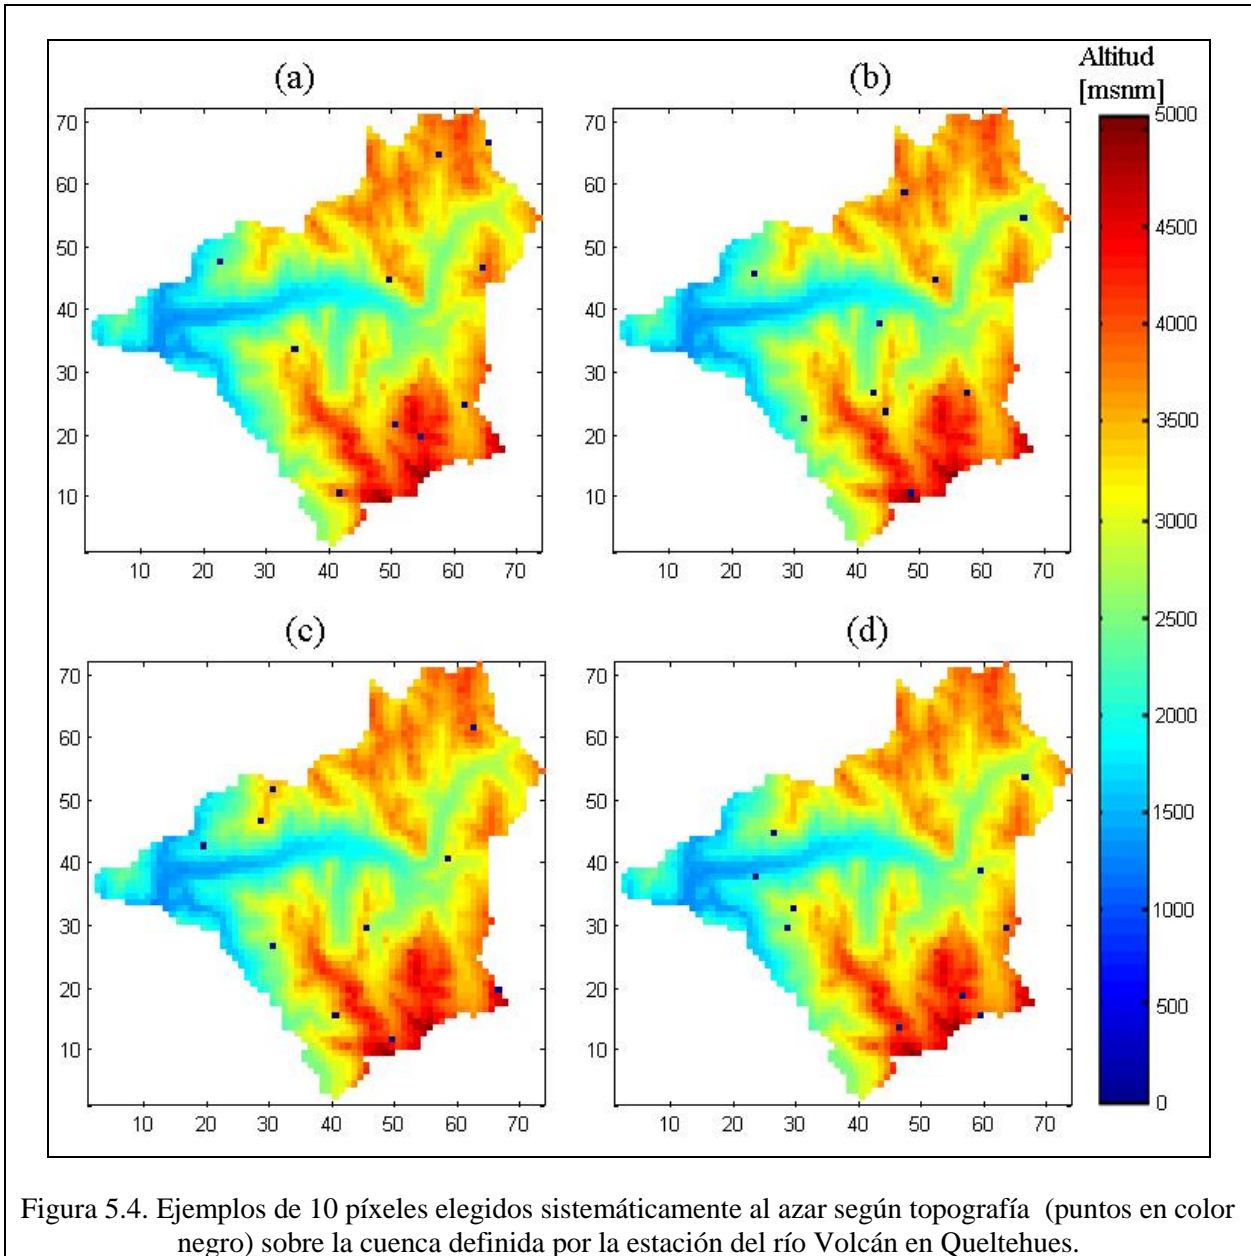


Figura 5.4. Ejemplos de 10 píxeles elegidos sistemáticamente al azar según topografía (puntos en color negro) sobre la cuenca definida por la estación del río Volcán en Queltehues.

5.3.3. Elección de Píxeles Sistemático al Azar según Cobertura

La cobertura de nieve concentrada en algunos sectores altos de la cuenca es otra alternativa como criterio de búsqueda de aquellos píxeles claves. Sin duda, el manto de nieve desaparecerá más rápido en aquellas regiones más bajas y por el contrario permanecerá por un tiempo mayor en las altas cumbres. Para el empleo de este criterio se procedió a generar un mapa en el que se acumuló el resultado de todas las

imágenes con filtro NDSI, dando como resultado un mapa en el que se puede reconocer la variabilidad del manto de nieve en el período de modelación. Para generar dicho mapa se sumaron las 359 imágenes NDSI, dando como resultado una matriz en la que cada elemento representa el nivel de acumulación de nieve asociado a un mismo píxel durante el período de modelación. En la Figura 5.5 se muestra el mapa generado para la cuenca del río Volcán y los píxeles seleccionados.

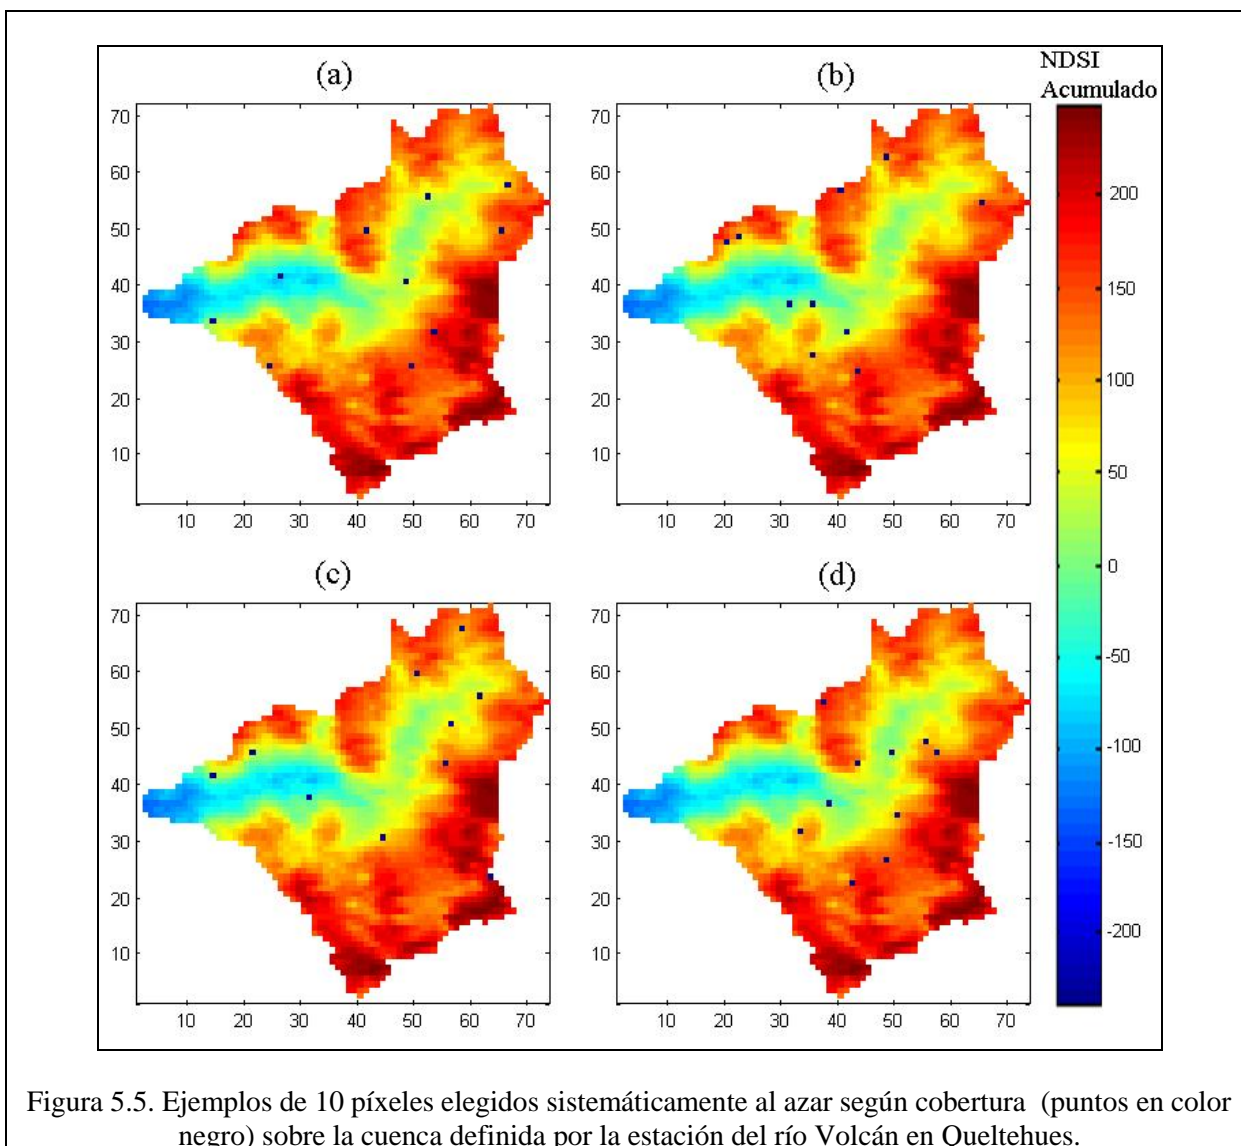


Figura 5.5. Ejemplos de 10 píxeles elegidos sistemáticamente al azar según cobertura (puntos en color negro) sobre la cuenca definida por la estación del río Volcán en Queltehués.

Dado que la aplicación del filtro NDSI sobre una imagen entrega valores entre -1 y 1, la sumatoria de estos valores sobre el total de imágenes puede entregar un mapa donde los límites pueden ser $[-1 \times N^\circ \text{ Imágenes}, 1 \times N^\circ \text{ Imágenes}]$, donde el límite superior será alcanzado por el pico de una montaña o volcán donde siempre existió nieve de buena calidad y, por lo tanto, cada imagen habrá logrado un umbral NDSI igual a 1. Estos mapas permiten clasificar las regiones de acumulación de nieve, del mismo modo que un mapa de isoyetas permite clasificar las regiones por nivel de concentración de la precipitación. En otro sentido, un mapa de acumulación se asemejará a un mapa topográfico debido a la relación directa entre las variables.

Para la selección de los píxeles sobre un mapa de acumulación se utilizó la misma pauta empleada en la selección por topografía, es decir:

- la diferencia entre el valor máximo y mínimo de cobertura acumulada se divide en 3 parte iguales, lo que permite definir 3 rangos de cotas: mínimo, medio y superior;
- del total de píxeles a encontrar, al menos 1 píxel representará al rango mínimo;
- una mitad de los píxeles restantes provendrán del rango medio y;
- la mitad restante provendrá del rango superior.

5.3.4. Elección de Píxeles en la Transecta central

De acuerdo a lo explicado en el CAPÍTULO 4.2.4, las transectas representan una alternativa de gran alcance como reconocedores de patrones y por lo tanto, una opción como información de entrada en la red neuronal. Para entender este criterio de selección es necesario explicar el término de transecta central. Este corresponde a un corte horizontal (u orientación E-O) sobre la cuenca, el cual pasa por el punto medio entre el límite norte y el límite sur de la misma. En la Figura 5.6 se muestran 4 ejemplos de selección de píxeles, con diferente número de píxeles sobre la transecta central.

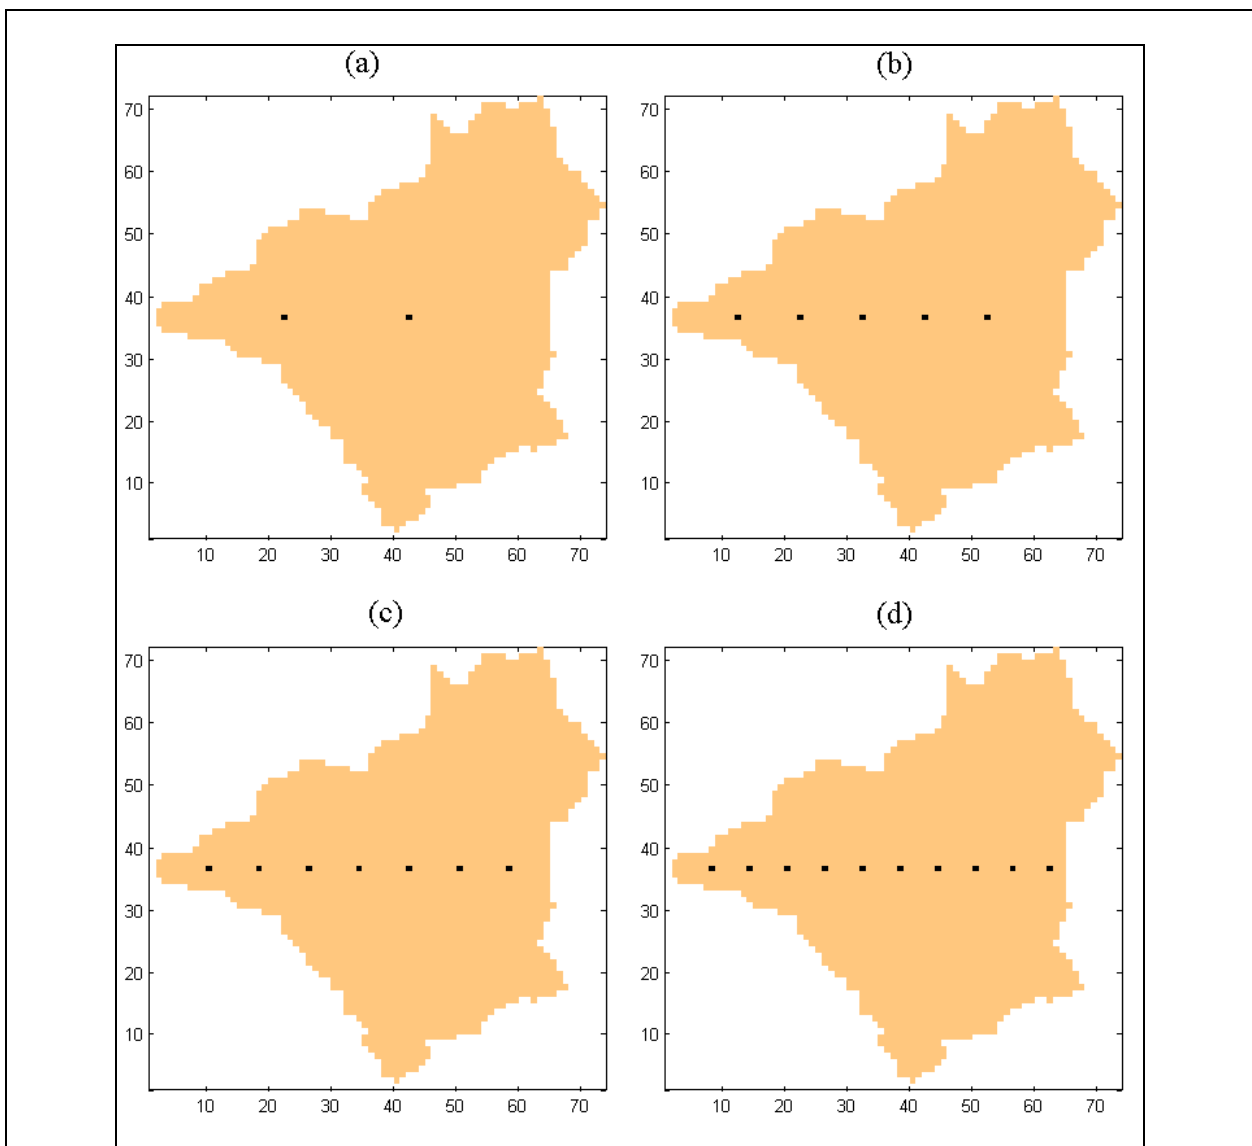


Figura 5.6. Ejemplos de selección de píxeles elegidos desde la transecta central (puntos en color negro) sobre la cuenca definida por la estación del río Volcán en Queltehues. (a) 2 píxeles; (b) 5 píxeles; (c) 7 píxeles; (d) 10 píxeles.

El mayor problema que se presenta ante el uso de esta modalidad corresponde al número elevado de píxeles que posee una transecta (>30 píxeles) que no es sustentable en la red debido al limitado número de imágenes que se tiene en este estudio. Para solucionar este problema es necesario elegir ciertos píxeles de la transecta, proceso de selección que se orientará de acuerdo a la topografía de la región. Como simplificación del problema se adoptará la transecta central de la cuenca y sobre ella se seleccionarán los píxeles de una manera uniformemente distribuida en la orientación E-O, de manera de conseguir información relevante tanto de las zonas altas como de las zonas bajas.

Esta modalidad sin dudas representa una alternativa de selección de información a partir del conjunto total de píxeles de la cuenca, puesto que busca incluir información variada de diferentes zonas de una manera guiada.

5.4. ARQUITECTURA DE LA RED

La definición de las condiciones iniciales y la arquitectura de la red es una de las etapas claves para resolver problemas mediante redes neuronales.

En la definición de las condiciones iniciales se encuentran elementos como tasa de aprendizaje, umbral de salida, épocas de entrenamiento y algoritmo de entrenamiento, los cuales serán definidos a priori. En la definición de la arquitectura, el número de capas ocultas, funciones de activación y número de nodos se ciñen a reglas heurísticas que en este trabajo se definen previamente por representar elementos básicos de selección. Es importante destacar que la omisión de análisis tanto en las condiciones iniciales como en la arquitectura básica se ha de realizar por el elevado número de pruebas necesario para evaluar cada variable, teniendo presente que se tienen 6 cuencas y 4 configuraciones de selección de píxeles.

Como objetivo de este capítulo se busca encontrar la mejor configuración de red para cada cuenca según los siguientes elementos, definidos como aquellos de mayor relevancia:

- variación unidades capa de entrada,
- variación unidades capa oculta,
- retardo temporal de las capas,
- inclusión desfase temporal entre series de NDSI y caudales,
- inclusión de serie de porcentaje de área cubierta.

Las condiciones iniciales de la red se muestran en la tabla 5.1. La función de activación para la capa de entrada es la tangente hiperbólica y lineal para la capa de salida. Matlab posee la implementación de diferentes algoritmos Backpropagation (BP) eficientes que permiten resolver el problema con diferente tiempo computacional y diferente rapidez de convergencia. El algoritmo específico a utilizar para el ajuste de pesos es el algoritmo BP Levenberg-Marquardt, el cual es uno de los algoritmos de convergencia más rápidos.

Tabla 5.1: Condiciones iniciales

Épocas de entrenamiento	100
Tasa de aprendizaje inicial	0,001
nodos: entrada-ocultas-salida	2-0-1
Retardo temporal	1

Ante la definición de una arquitectura característica para las 6 cuencas o la búsqueda de una arquitectura propia por cada una, se definió la segunda opción debido a las diferencias que existen entre cada una en torno a la variabilidad de la cobertura de nieve que posee cada una. Por su ubicación geográfica y tamaño, sobre algunas cuencas puede obtenerse un mejor resultado mediante la selección sistemática por topografía que en otras. Dichas diferencias y otras estudiadas en la presente investigación dan cuenta de la necesidad por evaluar cada cuenca con una arquitectura propia.

Si se tiene presente que por cada cuenca se debe evaluar las 4 alternativas de selección de la información de entrada, además de las 5 variaciones de la arquitectura de mayor relevancia, las combinaciones posibles por la búsqueda del mejor modelo representan una tarea de gran envergadura. A continuación se detallan los resultados de la búsqueda por la arquitectura más idónea para cada cuenca, donde prevalecerán los resultados numéricos por sobre los resultados gráficos.

5.5. ENTRENAMIENTO

La información disponible fue dividida de forma arbitraria para el entrenamiento, validación y prueba de la red, según se indica en la Tabla 5.2. De acuerdo a ello, se definió inicialmente el período de validación correspondiente al penúltimo año hidrológico (2006-07), y el período de entrenamiento correspondiente a la información restante, desde el año 2000 hasta el año 2006. En el período de prueba corresponde al último año con información fluviométrica no oficial (2007-08).

Tabla 5.2: Distribución porcentual de la información satelital.

Período Hidrológico	Imágenes	Etapa	Porcentaje [%]
1999-00	5	Entrenamiento	77,7
2000-01	46		
2001-02	44		
2002-03	46		
2003-04	46		
2004-05	46		
2005-06	46	Validación	12,8
2006-07	46		
2007-08	34*	Prueba-Predicción	9,5

Obs.: (*) La información fluviométrica disponible no permite incluir 12 períodos más, para completar el año con 46 imágenes.

La evaluación de los resultados en la búsqueda de la mejor configuración se realizará de forma gradual para cada cuenca, es decir, probando diferentes cantidades de nodos y períodos de desfase. Para evaluar la calidad del modelo se utilizarán las funciones objetivos definidas en el CAPÍTULO II: el error cuadrático medio (ECM) y el error cuadrático medio normalizado (ECMN), para 5 corridas simultáneas por cada prueba, vale decir, un mismo conjunto de series (asociados a determinado píxeles) constituirán la entrada a la red inicializada aleatoriamente en 5 oportunidades. Cada corrida involucra el ajuste de pesos de forma iterativa hasta alcanzar el error mínimo asignado de forma arbitraria, en caso de no alcanzar dicho valor se iterará las veces que se haya definido arbitrariamente. Para la evaluación conjunta de 5 corridas se utilizará el promedio y la desviación estándar del ECM y el ECMN.

5.5.1. Variación Unidades Capa de Entrada

En la selección del número de nodos de la capa de entrada, el cual corresponde al número de píxeles o series de tiempo de “existencia” de nieve en el píxel, se realizaron pruebas para 2, 4, 6 y 8 nodos. Como se señaló al principio de este capítulo, el número de series de entrada debe ser reducido por el elevado número de parámetros que se genera en la red neuronal.

Un ejemplo de la ubicación de la píxeles en la cuenca y la selección de la información de entrada a la red se muestra en la Figura 5.7. La configuración de la red neuronal con sus respectivos pesos se muestra en la Figura 5.8.

En la Figura 5.8 se observa que los pesos asociados a la capa de entrada son mayores a la unidad debido a los valores de caudales observados en la estación y que debe alcanzar la red en el proceso iterativo.




Figura 5.7. (a) Ejemplo de 2 píxeles elegidos al azar (puntos en color negro) sobre la cuenca definida por la estación del río Alicahue en Collihuay. (b) Series de tiempo de entrada a la red.

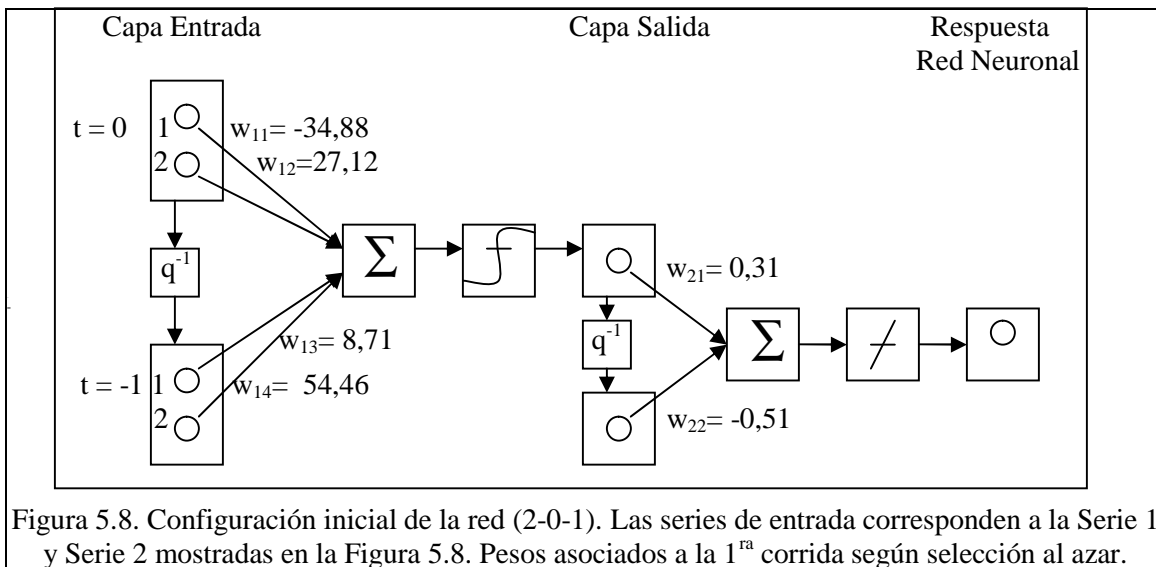


Figura 5.8. Configuración inicial de la red (2-0-1). Las series de entrada corresponden a la Serie 1 y Serie 2 mostradas en la Figura 5.8. Pesos asociados a la 1^{ra} corrida según selección al azar.

Los resultados en la cuenca del río Alicahue en Collihuay se muestran en las Tablas 5.3, a 5.6, donde se destaca el mejor resultado según configuración de selección de información en color naranja. Los resultados gráficos son mostrados en las Figuras 5.9, a 5.12 como promedios de las 5 corridas por cada tipo de selección en la información: azar, sistemático al azar según topografía (topografía), sistemático al azar según cobertura (cobertura), y transecta central (transecta).

Tabla 5.3. Configuración (2-0-1), estación Alicahue en Collihuay.

Corrida	Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
	ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
1	1.417	0.721	1.626	0.826	1.451	0.737	1.507	0.766
2	1.307	0.664	1.676	0.852	1.512	0.769	1.519	0.772
3	1.296	0.659	1.723	0.876	1.543	0.784	1.522	0.774
4	1.692	0.860	1.777	0.903	1.520	0.773	1.950	0.991
5	1.526	0.776	1.699	0.864	1.567	0.797	1.507	0.766
E(x)	1.448	0.736	1.700	0.864	1.519	0.772	1.601	0.814
s_x	0.166	0.084	0.056	0.029	0.044	0.022	0.195	0.099





Tabla 5.4. Configuración (4-0-1), estación Alicahue en Collihuay

Corrida	Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
	ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
1	1.341	0.681	1.389	0.706	1.238	0.629	1.432	0.728
2	1.276	0.649	1.299	0.660	1.292	0.657	1.912	0.972
3	1.289	0.655	1.717	0.873	1.182	0.601	1.436	0.730
4	1.389	0.706	1.198	0.609	1.153	0.586	1.310	0.666
5	1.361	0.692	1.273	0.647	1.158	0.589	1.326	0.674
E(x)	1.331	0.677	1.375	0.699	1.205	0.612	1.483	0.754
s_x	0.048	0.024	0.203	0.103	0.059	0.030	0.247	0.125

Al observar la Figura 5.9 se tiene que la respuesta de la red es similar para las diferentes configuraciones de selección de información, donde es posible distinguir las diferencias asociadas a los períodos de

acumulación y derretimiento de la nieve. La similitud de las respuestas está asociado a lo cual puede deberse al reducido número de nodos en la capa de entrada. Se espera que para un mayor número de nodos, la red pueda reconocer la variabilidad de los caudales en años secos y húmedos.



En la Figura 5.10 se aprecia la variabilidad anual de los caudales y se hace distinción entre años secos y húmedos. En la Tabla 5.5 se distingue la selección por cobertura.

Tabla 5.5. Configuración (6-0-1), estación Alichahue en Collihuay

Corrida	Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
	ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
1	1.048	0.533	0.892	0.454	0.848	0.431	0.853	0.433
2	1.025	0.521	0.955	0.486	0.734	0.373	1.632	0.830
3	1.151	0.585	0.979	0.497	0.907	0.461	1.050	0.534
4	1.212	0.616	1.000	0.509	0.808	0.411	1.013	0.515
5	1.125	0.572	0.936	0.476	0.874	0.444	0.932	0.474
E(x)	1.112	0.565	0.952	0.484	0.834	0.424	1.096	0.557
s _x	0.076	0.039	0.041	0.021	0.067	0.034	0.309	0.157

Los resultados gráficos muestran la dificultad que tiene el modelo neuronal en la modelación de los años secos respecto de los años húmedos o normales. Además, se aprecia claramente una mejor calidad en los resultados en la medida que aumenta el número de series en la capa de entrada.




Figura 5.11. Resultados promedios en la cuenca del río Alicahue para los diferentes tipos de selección de información, configuración de red 6-0-1.

Tabla 5.6. Configuración (8-0-1), estación Alicahue en Collihuay

Corrida	Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
	ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
1	0.563	0.286	0.600	0.305	0.509	0.259	0.718	0.365
2	0.556	0.283	0.404	0.205	0.581	0.295	0.748	0.380
3	0.539	0.274	0.394	0.200	1.135	0.577	0.742	0.377
4	0.525	0.267	0.393	0.200	0.623	0.317	0.858	0.436
5	0.492	0.250	0.462	0.235	0.610	0.310	0.639	0.325
E(x)	0.535	0.272	0.451	0.229	0.692	0.352	0.741	0.377
s_x	0.029	0.015	0.088	0.045	0.252	0.128	0.079	0.040

En la Tabla 5.7 se muestra el resumen de los resultados obtenidos para cada configuración de selección de información y cantidad de nodos. Los mejores resultados se muestran en negrita.

A partir de la Tabla 5.7 se observa una tendencia hacia mejores resultados en la medida que se aumenta el número de nodos en la capa de entrada, lo que involucra incluir una mayor cantidad de información, y conlleva a un mayor número de parámetros. Además, la selección por topografía resulta ser la más adecuada para la configuración de red elegida. Los resultados obtenidos según la selección al azar, indican que esta selección representa una alternativa de interés para la búsqueda de los píxeles que permitan estimar la escorrentía de deshielo.

Los modelos de redes neuronales son de tipo estocástico en los que la búsqueda de los parámetros por cada entrenamiento genera una respuesta diferente (Estévez, 2007). En la selección de información según la transecta central, el conjunto de entrada a la red siempre es el mismo, sin embargo, la respuesta de la red en el conjunto de las 5 corridas por cada prueba entrega una varianza mayor a 0 lo que deja de manifiesto la aleatoriedad de los valores iniciales de los pesos o parámetros.

Para las demás cuencas, la mejor configuración resultó ser aquella con 8 nodos en la capa de entrada. Los resultados se resumen en la Tablas 5.8. Los resultados parciales por cada cuenca se muestran en el Anexo III.




Figura 5.12. Resultados promedios en la cuenca del río Alichahue para los diferentes tipos de selección de información, configuración de red 8-0-1.

Tabla 5.7. Resumen resultados, variación nodos de entrada, río Alichahue.

Nodos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
2-0-1	E(x)	1.448	0.736	1.700	0.864	1.519	0.772	1.601	0.814
	s_x	0.166	0.084	0.056	0.029	0.044	0.022	0.195	0.099
4-0-1	E(x)	1.331	0.677	1.375	0.699	1.205	0.612	1.483	0.754
	s_x	0.048	0.024	0.203	0.103	0.059	0.030	0.247	0.125
6-0-1	E(x)	1.112	0.565	0.952	0.484	0.834	0.424	1.096	0.557
	s_x	0.076	0.039	0.041	0.021	0.067	0.034	0.309	0.157
8-0-1	E(x)	0.535	0.272	0.451	0.229	0.692	0.352	0.741	0.377
	s_x	0.029	0.015	0.088	0.045	0.252	0.128	0.079	0.040

Tabla 5.8. Resumen resultados, configuración de red: 8-0-1.

Cuenca		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
Alichahue en Collihuay	E(x)	0.535	0.272	0.451	0.229	0.692	0.352	0.741	0.377
	s_x	0.029	0.015	0.088	0.045	0.252	0.128	0.079	0.040
Putando en Resguardo	E(x)	27.817	0.264	47.369	0.450	23.462	0.223	42.917	0.407
	s_x	15.241	0.145	13.519	0.128	3.292	0.031	15.060	0.143
Juncal en Juncal	E(x)	5.087	0.168	8.058	0.266	2.915	0.096	3.754	0.124
	s_x	2.050	0.068	2.198	0.073	0.723	0.024	1.623	0.054
Pocuro en el Sifón	E(x)	0.288	0.223	0.195	0.151	0.244	0.189	0.210	0.163
	s_x	0.028	0.022	0.052	0.040	0.137	0.106	0.036	0.028
Volcán en Queltehues	E(x)	20.568	0.171	14.116	0.117	22.868	0.190	26.534	0.220
	s_x	9.638	0.080	3.499	0.029	10.488	0.087	19.532	0.162
Maipo en las Hualtatas	E(x)	177.902	0.187	365.867	0.385	264.386	0.278	307.011	0.323
	s_x	44.939	0.047	178.008	0.187	80.394	0.085	65.501	0.069

La mayoría de las cuencas en estudio muestran mejores resultados para un mayor número de nodos de entrada, lo que se debe a un mayor volumen de información a la red permitiéndole entender el

comportamiento de la escorrentía. En relación a la configuración de selección de información de entrada, la selección es sistemática es la más adecuada para la mayoría de las cuencas. La selección al azar puede entregar mejores resultados, como es el caso de la cuenca del río Maipo, en la cual el tamaño de la cuenca permite que la selección por azar o sistemática al azar tenga las mismas posibilidades. Los valores del ECMN son bajos para las diferentes cuencas, pero siguen siendo valores altos considerando que los resultados mostrados corresponden a la etapa de entrenamiento.

5.5.2. Variación Unidades Capa Oculta

Para determinar el número de neuronas ocultas, la red debe ser entrenada para luego evaluar el resultado obtenido. Si se aumenta demasiado el número de neuronas ocultas, se corre el riesgo de un sobreajuste a los datos de entrenamiento y se perderá la capacidad de generalización de la red, es decir, se memorizarán los datos de entrenamiento y la red presentará un mal desempeño frente a nuevos conjuntos de datos. Por otro lado, un número reducido de neuronas puede ser insuficiente para resolver el problema (Pérez, 2002)

El número de nodos en la capa oculta será evaluado considerando 6 y 8 nodos en la capa entrada. La información de entrenamiento disponible no es suficiente para incluir una capa oculta en la red de acuerdo a las reglas heurísticas, es por esto que los resultados serán considerados de carácter informativo y sólo se considerarán 1 y 2 nodos en la capa oculta. Los resultados se muestran en el Anexo III. En la Tabla 5.9 se muestra el resultado obtenido en la cuenca del río Juncal. En la Tabla 5.9 se muestra un resultado que representa el mismo desempeño de la red neuronal sobre todas las cuencas.

Tabla 5.9. Resumen resultados, variación nodos de capa oculta, río Juncal.

Nodos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-0-1	E(x)	9.362	0.309	6.402	0.211	8.427	0.278	9.533	0.315
	s_x	1.708	0.056	1.783	0.059	2.482	0.082	2.862	0.095
6-1-1	E(x)	15.241	0.503	25.574	0.845	18.723	0.618	23.285	0.769
	s_x	6.044	0.200	6.299	0.208	11.461	0.379	10.491	0.346
6-2-1	E(x)	14.445	0.477	15.541	0.513	22.540	0.744	17.791	0.588
	s_x	10.043	0.332	11.393	0.376	7.575	0.250	1.419	0.047
8-0-1	E(x)	5.087	0.168	8.058	0.266	2.915	0.096	3.754	0.124
	s_x	2.050	0.068	2.198	0.073	0.723	0.024	1.623	0.054
8-1-1	E(x)	16.187	0.535	26.429	0.873	20.511	0.677	22.953	0.758
	s_x	10.137	0.335	5.209	0.172	11.871	0.392	5.600	0.185
8-2-1	E(x)	15.729	0.519	18.600	0.614	6.053	0.200	12.503	0.413
	s_x	10.310	0.340	9.087	0.300	6.318	0.209	11.960	0.395

En general se observa que los resultados empeoran bastante para 1 o 2 nodos en la capa oculta. En todas las cuencas los resultados indican que no se recomienda incluir una capa oculta de 1 o 2 nodos, lo que puede deberse a la limitada información disponible. Ensayos preliminares mostraron que la existencia de una capa oculta permitía un mejor ajuste de los caudales bajos y aquellos de la temporada de deshielo, lo que puede significar una alternativa para el pronóstico en años secos.

5.5.3. Retardo Temporal de las Capas

El retardo temporal puede ser entendido como el número de elementos autorregresivos que puede incluir la red. Esta característica es la mayor ventaja que poseen las redes neuronales recurrentes temporales frente a fenómenos estacionales que sugieren una dependencia temporal. El siguiente análisis involucra diferentes retardos temporales, de 1, 2, 4, 6 y 7 períodos sobre la configuración de red: 8-1. Ensayos preliminares mostraron que el número de retardos estaba relacionado con el número de series temporales en la capa de entrada, encontrándose un máximo para obtener resultados aceptables de N-1 retardos,

donde N corresponde al número de series temporales. Sobre N retardos, la respuesta de la red era de menor calidad. En la Figura 5.13 se muestra un ejemplo para 4 series de entrada en la primera capa, en el que el número de retardos máximo es de 3 (4-1). Los resultados sobre las cuencas de los ríos Juncal y Volcán se muestran en las Tabla 5.11 y 5.12, respectivamente.

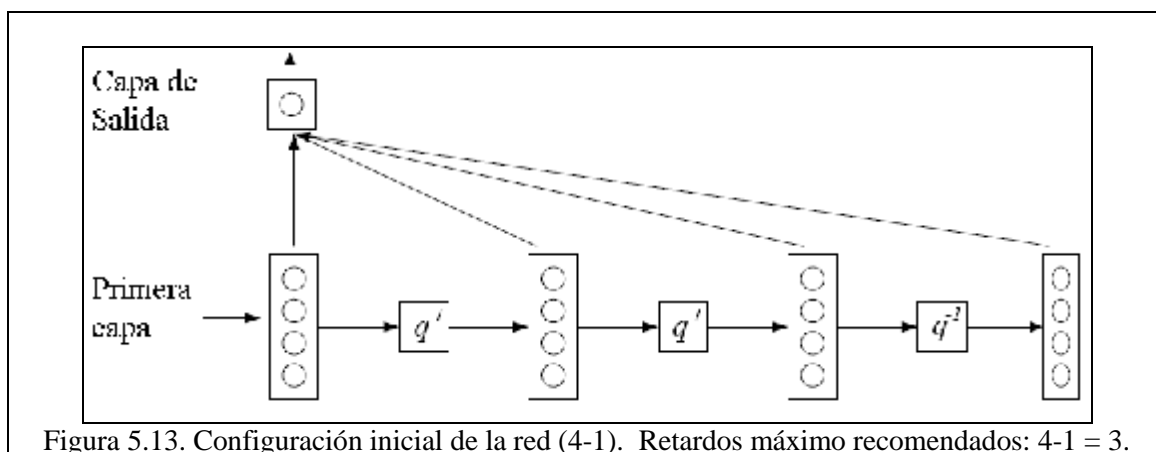


Tabla 5.10. Resumen resultados, retardo temporal sobre configuración: 8-1, río Juncal.

Retardos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
1	E(x)	5.087	0.168	8.058	0.266	2.915	0.096	3.754	0.124
	s_x	2.050	0.068	2.198	0.073	0.723	0.024	1.623	0.054
2	E(x)	58.703	1.939	60.893	2.011	58.446	1.930	58.528	1.933
	s_x	0.437	0.014	3.653	0.121	0.046	0.002	0.228	0.008
4	E(x)	60.365	1.993	58.489	1.932	58.547	1.933	58.975	1.948
	s_x	4.336	0.143	0.088	0.003	0.175	0.006	0.754	0.025
6	E(x)	61.517	2.032	60.427	1.996	60.435	1.996	58.965	1.947
	s_x	6.913	0.228	4.476	0.148	4.492	0.148	1.205	0.040
7	E(x)	59.015	1.949	59.276	1.958	62.140	2.052	58.784	1.941
	s_x	1.107	0.037	1.882	0.062	5.247	0.173	0.800	0.026

Tabla 5.11. Resumen resultados, retardo temporal sobre configuración: 8-1, río Volcán.

Retardos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
1	E(x)	16.285	0.135	18.993	0.158	18.495	0.153	26.430	0.219
	s_x	3.050	0.025	9.228	0.077	11.063	0.092	16.032	0.133
2	E(x)	193.764	1.607	190.360	1.579	192.875	1.600	191.180	1.586
	s_x	8.553	0.071	1.498	0.012	7.090	0.059	2.350	0.019
4	E(x)	192.817	1.599	192.196	1.594	197.512	1.638	199.112	1.651
	s_x	6.308	0.052	4.338	0.036	13.608	0.113	12.159	0.101
6	E(x)	194.804	1.616	194.465	1.613	198.059	1.643	191.992	1.592
	s_x	10.292	0.085	10.036	0.083	10.009	0.083	5.074	0.042
7	E(x)	190.948	1.584	189.744	1.574	203.517	1.688	191.447	1.588
	s_x	2.811	0.023	0.120	0.001	17.578	0.146	3.882	0.032

Sobre la variación del número de retardos en la capa de entrada se aprecia que los mejores resultados son obtenidos para un retardo de 1 período, lo que indica que la respuesta de la red neuronal no mejora en la medida que se agregan elementos autorregresivos. Este resultado se mantiene para las diferentes cuencas en estudio.

En relación a la selección de información de entrada, la selección por transecta es la que presenta los peores resultados. En el Anexo III, se muestran los resultados obtenidos en las demás cuencas.

5.5.4. Inclusión Desfase Temporal entre Series de Tiempo

Para generar un pronóstico de la escorrentía de deshielo es necesario desfasar la información de entrada a la red neuronal de manera que la respuesta corresponda a un tiempo tardío, y de esta manera, una vez que la red sea haya entrenado, se consiga estimar la escorrentía susceptible de ocurrir empleando un conjunto de información de cobertura inmediatamente anterior. El desfase entre las series es sin duda una alternativa para el análisis del aprendizaje supervisado de la red neuronal, puesto que como se analizó en el CAPITULO IV existe una relación de desfase entre la cobertura y el caudal de deshielo.

Para evaluar este aspecto, se desfasará la información de entrada a la red respecto del caudal en 0, 10, N y 20 períodos de tiempo, donde cada período queda definido por 8 días y N representa el valor de desfases obtenido de la mejor correlación cruzada para cada cuenca. Al llevar estos desfases a meses se tiene 0, 2.7, N y 5.3 meses aproximadamente.

Los resultados para cada cuenca evaluados para 6 y 8 nodos de entrada con 1 retardo, se muestran en las Tablas 5.12, a 5.17.

La tendencia general es que cada cuenca presenta una respuesta diferente ante la variante de la información desfasada, así, las cuencas ubicadas en el norte (río Alicahue, y río Putaendo) alcanzan mejores resultados para desfases de 10 ó 11 períodos (80 ó 88 días), y las cuencas en el sur de la región de estudio (río Volcán, y río Maipo) alcanzan los mejores resultados para desfases nulos y para 20 períodos (166 días). En relación a la selección de la información de entrada, la selección por transecta central es la más deficiente.

Tabla 5.12. Resumen resultados, variación desfase temporal entre series de tiempo, río Alicahue.

Nodos	Desf. Temp.		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-1	0	E(x)	1.112	0.565	0.952	0.484	0.834	0.424	1.096	0.557
		s_x	0.076	0.039	0.041	0.021	0.067	0.034	0.309	0.157
6-1	10	E(x)	0.470	0.241	0.556	0.285	0.448	0.229	0.559	0.286
		s_x	0.080	0.041	0.072	0.037	0.068	0.035	0.057	0.029
6-1	11	E(x)	0.427	0.218	0.450	0.230	0.454	0.232	0.526	0.269
		s_x	0.055	0.028	0.122	0.062	0.060	0.031	0.060	0.031
6-1	20	E(x)	0.984	0.493	0.890	0.446	0.971	0.487	0.912	0.457
		s_x	0.120	0.060	0.134	0.067	0.083	0.041	0.050	0.025
8-1	0	E(x)	0.535	0.272	0.451	0.229	0.692	0.352	0.741	0.377
		s_x	0.029	0.015	0.088	0.045	0.252	0.128	0.079	0.040
8-1	10	E(x)	0.308	0.158	0.207	0.106	0.319	0.163	0.322	0.165
		s_x	0.162	0.083	0.013	0.007	0.070	0.036	0.109	0.056
8-1	11	E(x)	0.241	0.123	0.216	0.111	0.288	0.147	0.237	0.121
		s_x	0.029	0.015	0.015	0.008	0.154	0.079	0.013	0.007
8-1	20	E(x)	0.586	0.294	0.460	0.231	0.596	0.299	0.595	0.298
		s_x	0.083	0.041	0.058	0.029	0.093	0.047	0.136	0.068

Tabla 5.13. Resumen resultados, variación desfase temporal entre series de tiempo, río Putaendo.

Nodos	Desf. Temp.		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-1	0	E(x)	46.672	0.443	54.877	0.521	63.780	0.605	54.330	0.516
		s_x	9.058	0.086	20.782	0.197	17.939	0.170	15.483	0.147
6-1	10	E(x)	32.739	0.314	42.029	0.403	34.568	0.331	25.457	0.244
		s_x	6.965	0.067	7.097	0.068	5.740	0.055	4.698	0.045
6-1	14	E(x)	33.724	0.324	26.156	0.251	28.551	0.274	28.718	0.276
		s_x	7.808	0.075	5.282	0.051	4.970	0.048	10.882	0.105
6-1	20	E(x)	48.230	0.462	36.681	0.351	37.392	0.358	40.312	0.386
		s_x	9.347	0.090	8.182	0.078	8.929	0.086	12.710	0.122
8-1	0	E(x)	27.817	0.264	47.369	0.450	23.462	0.223	42.917	0.407
		s_x	15.241	0.145	13.519	0.128	3.292	0.031	15.060	0.143
8-1	10	E(x)	20.669	0.198	23.022	0.221	19.484	0.187	30.824	0.295
		s_x	6.550	0.063	9.584	0.092	10.006	0.096	11.869	0.114
8-1	14	E(x)	24.956	0.240	25.455	0.245	26.576	0.255	20.088	0.193
		s_x	7.314	0.070	3.853	0.037	10.817	0.104	8.491	0.082
8-1	20	E(x)	21.087	0.202	33.862	0.324	32.543	0.312	26.147	0.250
		s_x	3.860	0.037	11.193	0.107	9.288	0.089	8.024	0.077

Tabla 5.14. Resumen resultados, variación desfase temporal entre series de tiempo, río Juncal.

Nodos	Desf. Temp.		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-1	0	E(x)	9.362	0.309	6.402	0.211	8.427	0.278	9.533	0.315
		s_x	1.708	0.056	1.783	0.059	2.482	0.082	2.862	0.095
6-1	10	E(x)	15.868	0.481	10.161	0.308	13.966	0.423	11.961	0.362
		s_x	4.799	0.145	1.295	0.039	2.416	0.073	2.254	0.068
6-1	19	E(x)	7.998	0.247	8.488	0.262	8.589	0.265	7.372	0.227
		s_x	2.379	0.073	1.698	0.052	2.136	0.066	0.839	0.026
6-1	20	E(x)	11.828	0.365	10.604	0.328	8.893	0.275	6.827	0.211
		s_x	2.435	0.075	2.460	0.076	1.980	0.061	1.729	0.053
8-1	0	E(x)	5.087	0.168	8.058	0.266	2.915	0.096	3.754	0.124
		s_x	2.050	0.068	2.198	0.073	0.723	0.024	1.623	0.054
8-1	10	E(x)	7.522	0.228	7.796	0.236	8.613	0.261	8.251	0.250
		s_x	2.467	0.075	0.879	0.027	3.149	0.095	2.616	0.079
8-1	19	E(x)	7.987	0.246	7.044	0.217	6.859	0.212	7.629	0.235
		s_x	2.711	0.084	2.648	0.082	2.377	0.073	2.506	0.077
8-1	20	E(x)	2.639	0.082	6.802	0.210	6.668	0.206	5.120	0.158
		s_x	1.469	0.045	1.709	0.053	2.032	0.063	2.571	0.079

Tabla 5.15. Resumen resultados, variación desfase temporal entre series de tiempo, río Pocuro.

Nodos	Desf. Temp.		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-1	0	E(x)	0.429	0.333	0.365	0.283	0.476	0.369	0.343	0.266
		s _x	0.038	0.030	0.030	0.023	0.069	0.053	0.011	0.008
6-1	10	E(x)	0.517	0.404	0.503	0.393	0.500	0.391	0.434	0.339
		s _x	0.020	0.016	0.054	0.042	0.064	0.050	0.091	0.071
6-1	15	E(x)	0.504	0.395	0.529	0.414	0.553	0.433	0.473	0.370
		s _x	0.044	0.035	0.072	0.056	0.045	0.036	0.125	0.098
6-1	20	E(x)	0.614	0.519	0.617	0.522	0.570	0.482	0.637	0.539
		s _x	0.069	0.058	0.020	0.017	0.085	0.072	0.028	0.023
8-1	0	E(x)	0.288	0.223	0.195	0.151	0.244	0.189	0.210	0.163
		s _x	0.028	0.022	0.052	0.040	0.137	0.106	0.036	0.028
8-1	10	E(x)	0.342	0.267	0.439	0.343	0.288	0.225	0.217	0.169
		s _x	0.019	0.015	0.059	0.046	0.032	0.025	0.041	0.032
8-1	15	E(x)	0.343	0.268	0.356	0.278	0.316	0.247	0.381	0.298
		s _x	0.017	0.013	0.040	0.031	0.046	0.036	0.048	0.037
8-1	20	E(x)	0.423	0.358	0.471	0.399	0.432	0.366	0.486	0.411
		s _x	0.115	0.097	0.042	0.035	0.081	0.068	0.105	0.088

Tabla 5.16. Resumen resultados, variación desfase temporal entre series de tiempo, río Volcán.

Nodos	Desf. Temp.		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-1	0	E(x)	31.812	0.264	33.175	0.275	27.406	0.227	29.980	0.249
		s _x	13.386	0.111	4.766	0.040	7.905	0.066	3.682	0.031
6-1	10	E(x)	43.917	0.344	48.649	0.382	45.596	0.358	47.217	0.370
		s _x	7.934	0.062	14.528	0.114	7.698	0.060	14.734	0.116
6-1	17	E(x)	42.647	0.337	49.538	0.392	41.175	0.326	38.136	0.302
		s _x	4.314	0.034	8.586	0.068	4.926	0.039	7.246	0.057
6-1	20	E(x)	28.386	0.224	33.866	0.267	27.712	0.219	21.056	0.166
		s _x	5.468	0.043	9.321	0.074	8.499	0.067	5.657	0.045
8-1	0	E(x)	20.568	0.171	14.116	0.117	22.868	0.190	26.534	0.220
		s _x	9.638	0.080	3.499	0.029	10.488	0.087	19.532	0.162
8-1	10	E(x)	34.703	0.272	27.221	0.213	25.904	0.203	25.504	0.200
		s _x	15.015	0.118	3.637	0.029	11.078	0.087	6.400	0.050
8-1	17	E(x)	33.156	0.262	32.976	0.261	32.852	0.260	25.464	0.201
		s _x	8.053	0.064	12.801	0.101	10.817	0.086	4.013	0.032
8-1	20	E(x)	26.089	0.206	34.096	0.269	25.905	0.205	14.578	0.115
		s _x	6.198	0.049	7.974	0.063	8.382	0.066	5.512	0.044

Tabla 5.17. Resumen resultados, variación desfase temporal entre series de tiempo, río Maipo.

Nodos	Desf. Temp.		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-1	0	E(x)	314.492	0.331	378.264	0.398	359.951	0.379	380.328	0.401
		s _x	116.071	0.122	87.451	0.092	196.167	0.207	133.811	0.141
6-1	10	E(x)	528.284	0.495	661.320	0.620	468.423	0.439	511.022	0.479
		s _x	104.844	0.098	159.340	0.149	67.111	0.063	125.137	0.117
6-1	17	E(x)	387.546	0.369	364.896	0.347	374.701	0.356	445.649	0.424
		s _x	143.326	0.136	98.871	0.094	98.179	0.093	106.012	0.101
6-1	20	E(x)	323.674	0.309	290.758	0.278	341.079	0.326	325.044	0.310
		s _x	69.757	0.067	89.404	0.085	77.789	0.074	69.004	0.066
8-1	0	E(x)	177.902	0.187	365.867	0.385	264.386	0.278	307.011	0.323
		s _x	44.939	0.047	178.008	0.187	80.394	0.085	65.501	0.069
8-1	10	E(x)	426.837	0.400	526.102	0.493	459.265	0.431	537.352	0.504
		s _x	58.710	0.055	38.597	0.036	128.952	0.121	50.418	0.047
8-1	17	E(x)	490.403	0.466	439.755	0.418	451.658	0.430	372.259	0.354
		s _x	72.249	0.069	77.349	0.074	57.231	0.054	76.317	0.073
8-1	20	E(x)	576.219	0.550	335.127	0.320	311.454	0.297	297.074	0.284
		s _x	62.943	0.060	41.635	0.040	77.998	0.074	63.865	0.061

5.5.5. Inclusión de Serie de Porcentaje de Área Cubierta

Una de las últimas evaluaciones de interés sobre la arquitectura de la red es la inclusión de una de las series temporales de mayor interés que representa el comportamiento de toda la cuenca y que corresponde a la series de porcentaje de área cubierta de nieve.

La evaluación de esta configuración se hará sobre dos configuraciones de redes neuronales, una que posea un numero reducido de series asociadas a píxeles (configuración: 4-1, con 3 series provenientes de píxeles), y la otra que posea 8 series en total como entrada (configuración: 8-1, con 7 series provenientes de píxeles). De acuerdo a las configuraciones indicadas, la 4ª y 8ª serie, corresponderá a la serie de porcentaje de cobertura. Además, para evaluar diferentes series de porcentajes de cobertura según el NDSI, se utilizarán las series obtenidas para NDSI = 0.4 y 0.7. Los resultados para cada cuenca se aprecian en las Tablas 5.18, a 5.23, donde se destacan en negrita aquellos resultados de mejor calidad según cnfiguración y en color naranja aquel resultado de mejor desempeño según la selección de la información. Además, se incluyen los resultados obtenidos para la configuración de red: 8-1, en la que los 8 nodos de entrada corresponden a series asociadas a píxeles elegidos, es decir, sin series NDSI (SIN, en las Tablas).

Tabla 5.18. Resumen resultados, inclusión de serie de porcentaje de nieve, río Alichahue.

Nodos	NDSI		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
8-1	SIN	E(x)	0.535	0.272	0.451	0.229	0.692	0.352	0.741	0.377
		s _x	0.029	0.015	0.088	0.045	0.252	0.128	0.079	0.040
4-1	0.4	E(x)	1.340	0.681	1.381	0.702	1.262	0.641	1.371	0.697
		s _x	0.160	0.081	0.090	0.046	0.109	0.055	0.038	0.019
8-1	0.4	E(x)	0.704	0.358	0.553	0.281	0.476	0.242	0.740	0.376
		s _x	0.059	0.030	0.050	0.026	0.028	0.014	0.062	0.031
4-1	0.7	E(x)	1.318	0.670	1.304	0.663	1.335	0.679	1.320	0.671
		s _x	0.072	0.037	0.118	0.060	0.052	0.027	0.023	0.012
8-1	0.7	E(x)	0.626	0.318	0.528	0.268	0.653	0.332	0.776	0.395
		s _x	0.067	0.034	0.028	0.014	0.132	0.067	0.116	0.059

Tabla 5.19. Resumen resultados, inclusión de serie de porcentaje de nieve, río Putaendo.

Nodos	NDSI		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
8-1	SIN	E(x)	27.817	0.264	47.369	0.450	23.462	0.223	42.917	0.407
		s _x	15.241	0.145	13.519	0.128	3.292	0.031	15.060	0.143
4-1	0.4	E(x)	68.018	0.646	78.816	0.748	73.336	0.696	71.658	0.680
		s _x	5.151	0.049	12.307	0.117	1.937	0.018	9.138	0.087
8-1	0.4	E(x)	36.241	0.344	28.287	0.268	31.610	0.300	28.673	0.272
		s _x	9.508	0.090	12.088	0.115	13.080	0.124	9.581	0.091
4-1	0.7	E(x)	82.807	0.786	78.590	0.746	67.651	0.642	81.592	0.775
		s _x	11.486	0.109	18.202	0.173	13.128	0.125	13.585	0.129
8-1	0.7	E(x)	50.106	0.476	27.607	0.262	21.943	0.208	26.711	0.254
		s _x	21.166	0.201	6.601	0.063	7.128	0.068	6.427	0.061

Tabla 5.20. Resumen resultados, inclusión de serie de porcentaje de nieve, río Juncal.

Nodos	NDSI		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
8-1	SIN	E(x)	5.087	0.168	8.058	0.266	2.915	0.096	3.754	0.124
		s _x	2.050	0.068	2.198	0.073	0.723	0.024	1.623	0.054
4-1	0.4	E(x)	13.006	0.430	12.519	0.413	14.658	0.484	14.661	0.484
		s _x	2.172	0.072	3.341	0.110	1.472	0.049	1.549	0.051
8-1	0.4	E(x)	3.878	0.128	4.100	0.135	4.316	0.143	4.570	0.151
		s _x	0.597	0.020	1.024	0.034	1.347	0.044	1.280	0.042
4-1	0.7	E(x)	13.949	0.461	16.045	0.530	13.279	0.439	13.935	0.460
		s _x	2.197	0.073	2.052	0.068	4.421	0.146	1.441	0.048
8-1	0.7	E(x)	3.479	0.115	7.992	0.264	4.792	0.158	5.260	0.174
		s _x	2.129	0.070	3.785	0.125	1.609	0.053	2.339	0.077

Tabla 5.21. Resumen resultados, inclusión de serie de porcentaje de nieve, estero Pocuro.

Nodos	NDSI		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
8-1	SIN	E(x)	0.288	0.223	0.195	0.151	0.244	0.189	0.210	0.163
		s _x	0.028	0.022	0.052	0.040	0.137	0.106	0.036	0.028
4-1	0.4	E(x)	0.672	0.521	0.669	0.519	0.739	0.573	0.571	0.443
		s _x	0.011	0.009	0.045	0.035	0.028	0.021	0.052	0.041
8-1	0.4	E(x)	0.229	0.178	0.296	0.230	0.254	0.197	0.227	0.176
		s _x	0.027	0.021	0.139	0.108	0.055	0.043	0.058	0.045
4-1	0.7	E(x)	0.710	0.550	0.753	0.584	0.724	0.562	0.632	0.490
		s _x	0.086	0.066	0.044	0.034	0.046	0.036	0.133	0.103
8-1	0.7	E(x)	0.228	0.177	0.196	0.152	0.237	0.184	0.207	0.160
		s _x	0.025	0.019	0.033	0.025	0.062	0.048	0.009	0.007

Tabla 5.22. Resumen resultados, inclusión de serie de porcentaje de nieve, río Volcán.

Nodos	NDSI		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
8-1	SIN	E(x)	20.568	0.171	14.116	0.117	22.868	0.190	26.534	0.220
		s_x	9.638	0.080	3.499	0.029	10.488	0.087	19.532	0.162
4-1	0.4	E(x)	42.687	0.354	58.929	0.489	34.879	0.289	59.509	0.494
		s_x	0.491	0.004	1.304	0.011	3.009	0.025	11.016	0.091
8-1	0.4	E(x)	15.891	0.132	14.142	0.117	17.094	0.142	21.009	0.174
		s_x	2.119	0.018	5.009	0.042	3.373	0.028	3.345	0.028
4-1	0.7	E(x)	54.337	0.451	78.445	0.651	56.029	0.465	53.455	0.443
		s_x	7.380	0.061	10.047	0.083	13.324	0.111	4.968	0.041
8-1	0.7	E(x)	23.099	0.192	14.376	0.119	21.938	0.182	23.461	0.195
		s_x	7.448	0.062	6.254	0.052	6.063	0.050	4.827	0.040

Tabla 5.23. Resumen resultados, inclusión de serie de porcentaje de nieve, río Maipo.

Nodos	NDSI		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
8-1	SIN	E(x)	177.902	0.187	365.867	0.385	264.386	0.278	307.011	0.323
		s_x	44.939	0.047	178.008	0.187	80.394	0.085	65.501	0.069
4-1	0.4	E(x)	516.941	0.544	322.552	0.340	495.701	0.522	671.259	0.707
		s_x	241.472	0.254	31.341	0.033	278.692	0.293	228.834	0.241
8-1	0.4	E(x)	243.720	0.257	206.319	0.217	220.054	0.232	215.679	0.227
		s_x	87.688	0.092	82.188	0.087	64.709	0.068	78.325	0.082
4-1	0.7	E(x)	484.540	0.510	531.724	0.560	474.199	0.499	526.556	0.555
		s_x	44.338	0.047	258.156	0.272	56.881	0.060	244.036	0.257
8-1	0.7	E(x)	354.724	0.374	438.936	0.462	234.536	0.247	225.316	0.237
		s_x	144.201	0.152	138.443	0.146	88.836	0.094	75.153	0.079

En general, la inclusión de la serie de porcentaje mejora moderadamente los resultados obtenidos con una configuración donde el total de las series provienen de píxeles. En las cuencas de los ríos Alicahue y Juncal no existen mejoras en el desempeño de la red. La existencia de un reducido número de series de entrada implica resultados de menor calidad, lo que significa que la serie NDSI posee una importancia limitada sobre el total de las series.

El tipo de selección de la información de entrada no reconoce un esquema único como el de mejor desempeño para todas las cuencas; esto indica que todos los esquemas de búsqueda y selección son factibles de emplear, salvo el esquema por transecta central que posee un menor desempeño general.

5.6. VALIDACIÓN DE LOS RESULTADOS

Cada cuenca posee una configuración de red, asociada a un tipo de selección de información que entrega resultados numéricos comparativamente mejores que las demás configuraciones. Cuando se trabaja con redes neuronales, el proceso de validación es más riguroso que otros planteamientos de modelación, debido a que es necesario realizar 2 validaciones empleando 2 conjuntos de información diferentes, el conjunto de validación propiamente tal y el de prueba. Ante la limitación de un reducido número de años con información, se empleará el conjunto de prueba para validar el pronóstico de la red neuronal, dejando el conjunto de validación para el proceso de análisis que se plantea en el presente capítulo. Para evaluar el desempeño de la respuesta, se compararán los volúmenes observados y simulados asociados a dichos resultados. Se debe aclarar que los resultados de la validación corresponden a la evaluación que se realiza con la red neuronal entrenada con un conjunto de información diferente conjunto de entrenamiento. En la Tabla 5.24 se muestra el resumen de los resultados y en la Figura 5.14 se muestran los resultados gráficos

para cada cuenca. Cada resultado corresponde al promedio de 5 corridas o ejecuciones de la red neuronal inicializada aleatoriamente.

Es importante señalar que la respuesta de la red neuronal puede ser negativa, es decir, en la serie de caudales simulados, pueden existir valores negativos. Esta situación se produce debido a errores de la información de entrada, en la que la cobertura nubosa altera la imagen en todos los píxeles seleccionados y entrega valores bajos de NDSI, haciendo que la red neuronal reconozca una nueva condición y entregue un valor de caudal negativo. Para eliminar posibles respuestas negativas de la red neuronal, es necesario eliminar la información que puede generar este tipo de respuesta, sin embargo, la búsqueda de la información inadecuada es una tarea tediosa. Debido a que un caudal negativo no tiene significado físico, se procedió a eliminar dichos valores antes de evaluar el desempeño de la respuesta, en el volumen simulado.

Tabla 5.24. Resumen resultados, validación del modelo de red neuronal.

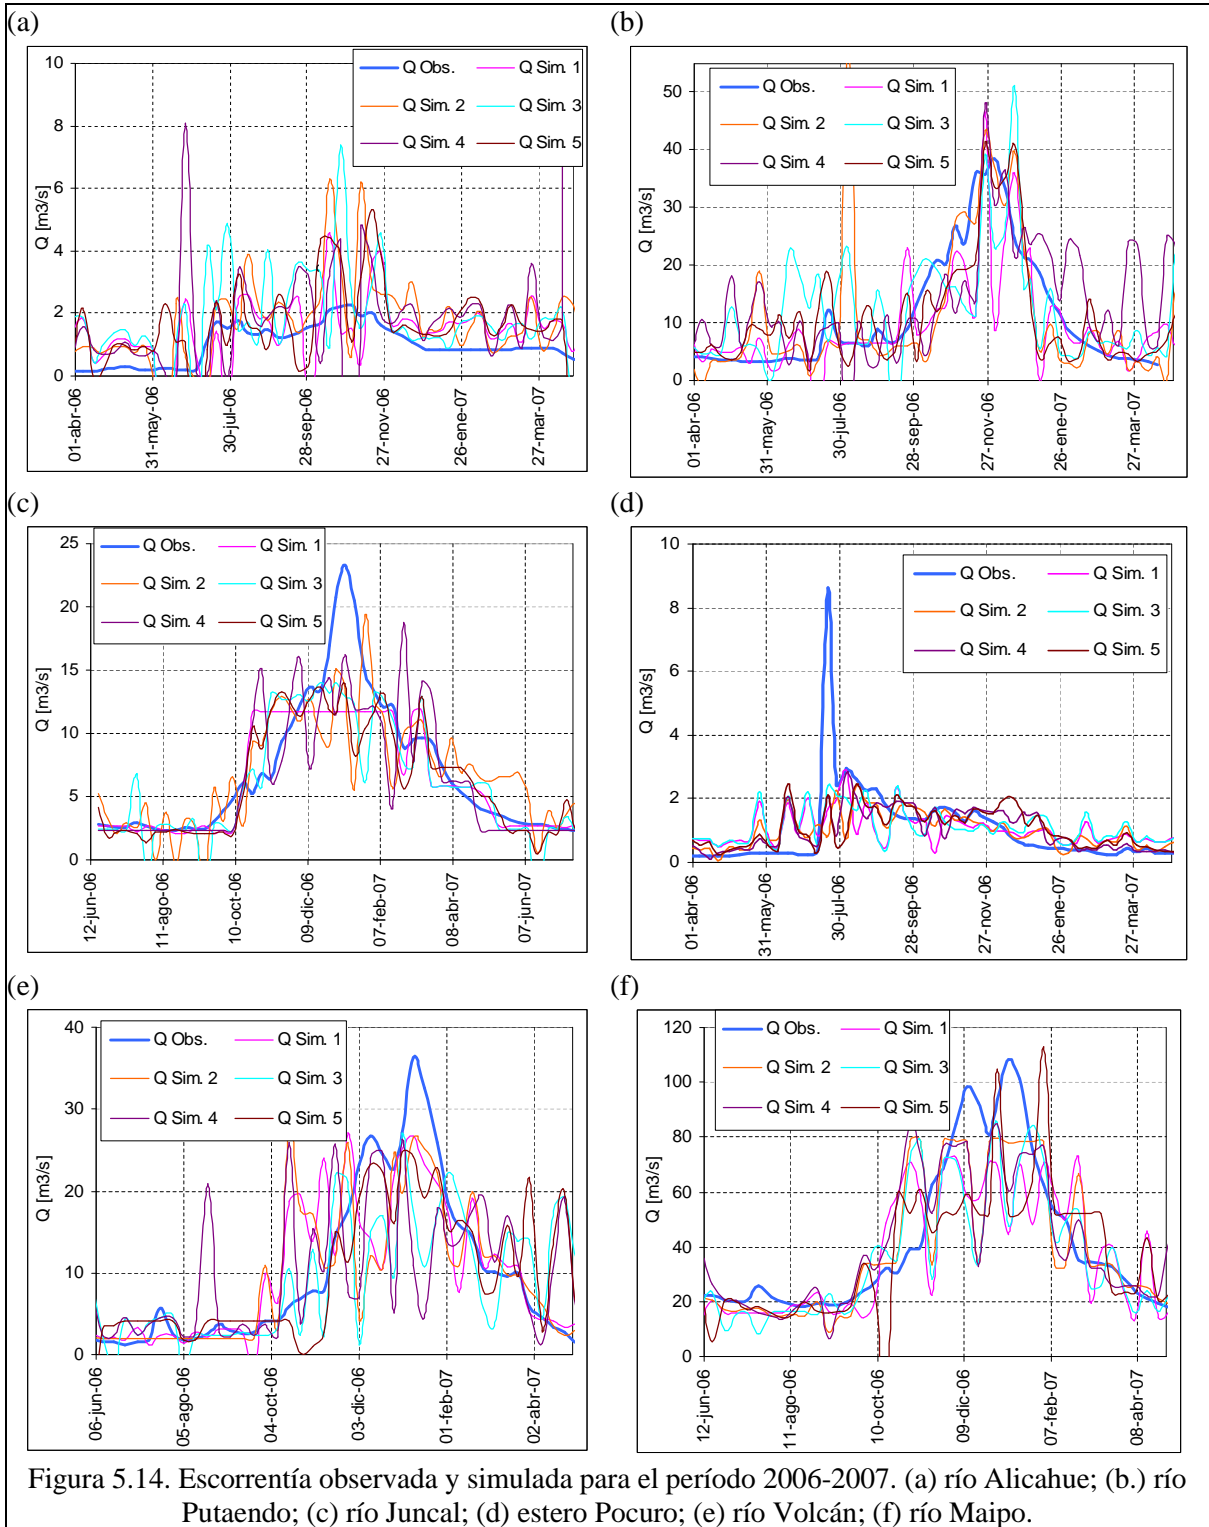
Cuenca	Modelo					Vol _{obs} [mill. m ³]	Vol _{sim.} [mill. m ³]	Desv. Est.	Error %
	Info.	Nodos	Retardos	Desfase serie Q	NDSI				
Alicahue	Topo.	8-1	1	0	SIN	32.95	39.84	12.15	35
Putando	Trans.	8-1	1	11	0.4	376.12	366.20	33.38	-7
Juncal	Cober.	4-1	1	0	0.4	246.79	225.12	11.93	-9
Pocuro	Azar	4-1	1	0	0.4	34.73	36.08	1.63	5
Volcán	Trans.	6-1	1	17	SIN	303.37	295.90	16.30	-4
Maipo	Topo.	8-1	1	17	SIN	1348.36	1264.51	65.14	-5

Obs.: Topo.=Sistemático al azar según Topografía; Trans.= Transecta central; Cober.= Sistemático al azar según Cobertura.

En la Tabla 5.24 se observan diferentes arquitecturas y modelos para cada una de las cuencas, lo que no permite identificar una arquitectura única ni un modelo único, para la generalización de una estructura única capaz de resolver el problema planteado. A partir del error porcentual entre volumen observado y simulado, se destaca que para todas las cuencas, salvo la cuenca del río Alicahue, el error es menor al 10%.

Los resultados gráficos muestran la variabilidad temporal de la escorrentía, en el que se aprecia la crecida de deshielo sujeta a fluctuaciones instantáneas producto de la información de entrada a la red neuronal. En general, las fluctuaciones que simulan una escorrentía negativa son de carácter puntual, lo que permitiría realizar un seguimiento a las series de entrada y eliminar las imágenes que poseen una alta interferencia atmosférica.

En un análisis particular por cuenca, se observa que en la cuenca del río Alicahue existen fluctuaciones en la simulación que ocurren antes y después de la crecida máxima observada, lo que da origen a una sobreestimación importante del volumen de deshielo (ver Tabla 5.24). En la cuenca del río Putando, se observa que las fluctuaciones son moderadas en torno al valor observado y generan una sobreestimación del volumen total simulado. En la cuenca del río Juncal se aprecia que el valor máximo de la escorrentía observada no se alcanza con las simulaciones, lo cual sugiere que el modelo asociado no es apto para períodos húmedos en el que es esperable tener grandes acumulaciones y un valor máximo para la crecida de deshielo; además se distingue que la escorrentía simulada posee la misma forma de la curva de porcentaje de cobertura de nieve, con una pendiente al inicio y al final del período y un máximo que tiende a ser constante. En la cuenca del estero Pocuro tampoco es modelado el caudal máximo, sin embargo, los resultados numéricos indican que la diferencia entre el volumen observado y simulado no es significativa. En la cuenca del río Volcán tampoco se alcanza la escorrentía máxima y se aprecian muchas fluctuaciones después de alcanzar el máximo. En la cuenca del río Maipo las fluctuaciones son bajas, y los resultados numéricos demuestran una leve sobreestimación de la escorrentía.



CAPÍTULO VI PRONÓSTICO DEL VOLUMEN NIVAL

6.1. INTRODUCCIÓN

El resultado del pronóstico de la escorrentía de deshielo es sin duda uno de los mayores alcances del presente trabajo, por cuanto, representa una alternativa para la gestión de los recursos hídricos durante la temporada de estiaje. El volumen disponible a principios del mes de Septiembre y la distribución mensual de dicho pronóstico son las mayores interrogantes para los tomadores de decisión en la distribución del agua.

Las fuentes de información utilizadas son una limitante para la evaluación del pronóstico, por cuanto existe información suficiente para entrenar y validar, pero no necesariamente para la etapa de prueba requerida por el modelo de red neuronal. Además, el desfase temporal necesario para el pronóstico, genera una pérdida importante de información, debido a que se debe cortar la serie de tiempo para mantener la ventana de información con la misma longitud, es decir, se debe mantener el mismo número de datos por cada serie. Para suplir esta pérdida en la etapa de prueba de la red neuronal, se utilizó información fluviométrica no oficial del período enero-marzo del año 2008. En la generación del pronóstico se evaluaron diferentes desfases seleccionados de forma arbitraria. Las cuencas que poseen información de este último período son:

- Estación río Juncal en Juncal
- Estación río Volcán en Queltehues
- Estación río Maipo en Las Hualtatas

6.2. RESULTADOS

En la etapa de validación se determinó una arquitectura característica para cada cuenca (ver Tabla 5.24), sujeto además a un desfase temporal definido a priori. Al emplear una misma arquitectura con diferentes desfases puede suceder que la respuesta no sea la óptima generándose un error en aumento en la medida que se empleen desfases mayores, por cuanto está involucrada una mayor pérdida de información.

Es importante señalar que la generación de pronósticos permite realizar diferentes tipos de análisis, ya que el modelo de red neuronal, entrenado para un desfase en particular, puede ser empleado en diferentes tiempos, ya sean en instantes previos a una fecha en particular, como también para instantes posteriores. Para aclarar lo anterior, se puede considerar el caso de un desfase de dos períodos, en el que además de conocer la respuesta para una fecha X, es posible evaluar dicha respuesta en el período siguiente teniendo la información de la fecha X+1. Para el caso de una red entrenada para 20 períodos (180 días) de desfase, la respuesta permite conocer la escorrentía con 20 períodos de antelación pero, al disponer de la información de cobertura previa, es posible determinar el pronóstico de la red para los períodos anteriores.

Una tercera alternativa corresponde a la generación de un pronóstico sucesivo que incluya la respuesta de los modelos entrenados para diferentes desfases, permitiendo la construcción de la escorrentía a partir de la misma información de entrada. De esta manera, al tener disponible la información de cobertura de nieve en la cuenca el día 1 de Septiembre, es posible emplear la red entrenada para 1 desfase y conocer el pronóstico para el día 9 de Septiembre, luego agregar la respuesta de la red entrenada para 2 desfases y conocer el pronóstico para el día 17 de Septiembre, y seguir sucesivamente con los demás modelos, para generar el pronóstico para un período de N desfases ($N \times 8$ días) en el futuro, en la medida que se haya generado un modelo de red para N desfases.

De acuerdo a lo obtenido en la etapa de entrenamiento y validación, la respuesta de la red está sujeta a fluctuaciones producto de la información de entrada. Para evaluar el desempeño de la red en el pronóstico, en cada cuenca, se consideró la respuesta obtenida según la arquitectura definida previamente para tres modelos diferentes de red neuronal, por cada desfase¹.

Los desfases definidos arbitrariamente son: 1, 2, 4, 6, 8, 10, 12, 14, 16, 18, 20 y 22 períodos. Para la evaluación de los resultados se utilizó el volumen total pronosticado.

6.2.1. Estación río Juncal en Juncal

En la Tabla 6.1 se muestra el resumen de los resultados numéricos, para desfases de 1, 2, 4, 6, 10 y 20 períodos, cuando se realiza el pronóstico desde el día 1 de Septiembre con los modelos entrenados, empleando tres conjuntos de información diferentes (información de cobertura en diferentes píxeles).

La evaluación de los resultados se realizó de forma independiente para los tres modelos generados para un mismo desfase. De esta manera, los volúmenes generados, considerando 1 desfase, son independientes de aquellos generados para 2 desfases, y así sucesivamente. Lo anterior señala que para la evaluación de un modelo de 20 desfases, fue necesario generar la serie continua hacia atrás en el tiempo, haciendo uso de la información observada antes del día 1 de Septiembre. La importancia de un análisis enfocado en un mismo modelo radica en la evaluación particular de cada uno, como potencial generador de la serie pronosticada completa.

Tabla 6.1. Pronóstico de volúmenes de deshielo (desde el 1 de Septiembre de 2007), en la cuenca del río Juncal. Evaluación de modelos generados para diferentes desfases.

Desfases	1	2	4	6	10	20
Tiempo [días]	8	16	32	48	80	160
Vol.OBSERVADO [mill.m ³]	3.11	5.00	6.69	11.03	24.35	54.53
Vol.PRONOSTICADO [mill.m ³]	3.23	4.86	7.04	10.75	24.49	70.38
Error %	8.26	-2.70	5.35	-2.57	0.58	29.06

Obs.: El volumen pronosticado corresponde al promedio de los 3 modelos utilizados en esta cuenca.

A partir de la Tabla 6.1, se observa que los errores del pronóstico son menores al 10%, salvo para un desfase de 20 períodos, lo que indica que la respuesta de cada modelo de red neuronal resulta ser satisfactoria, permitiendo determinar el volumen de la escorrentía hasta con tres meses de anticipación (80 días ~ 3 meses).

Al aumentar el desfase de la información, la incertidumbre es mayor y los volúmenes pronosticados alcanzan una sobrestimación del 30%. Esto indica que la red neuronal reconoce la existencia de un volumen disponible para el deshielo mayor al observado, o dicho de otra manera, la red pronostica un derretimiento acelerado de la nieve durante algún período. Una explicación al resultado obtenido es la existencia de un contenido de frío importante en el manto, que no pudo ser incluido como información de entrada.

En la Figura 6.1 se muestran los resultados gráficos obtenidos para desfases de 2, 6, 10 y 20 períodos, desde el 1 de Septiembre hasta el 27 de Diciembre. La respuesta de cada modelo considera conocida la información observada de la escorrentía con 2 períodos de antelación. La importancia de este tipo de análisis radica en la posibilidad de comparar las respuestas de cada uno de los modelos generados para diferentes desfases.

¹ Según la Tabla 5.24, los modelos son del tipo sistemático al azar según topografía o cobertura, por lo que se tienen diferentes píxeles en cada modelo. En el caso de la selección según transecta central, aunque los píxeles son siempre los mismos, el procedimiento de entrenamiento conduce a parámetros (pesos) diferentes debido a la inicialización al azar de éstos.

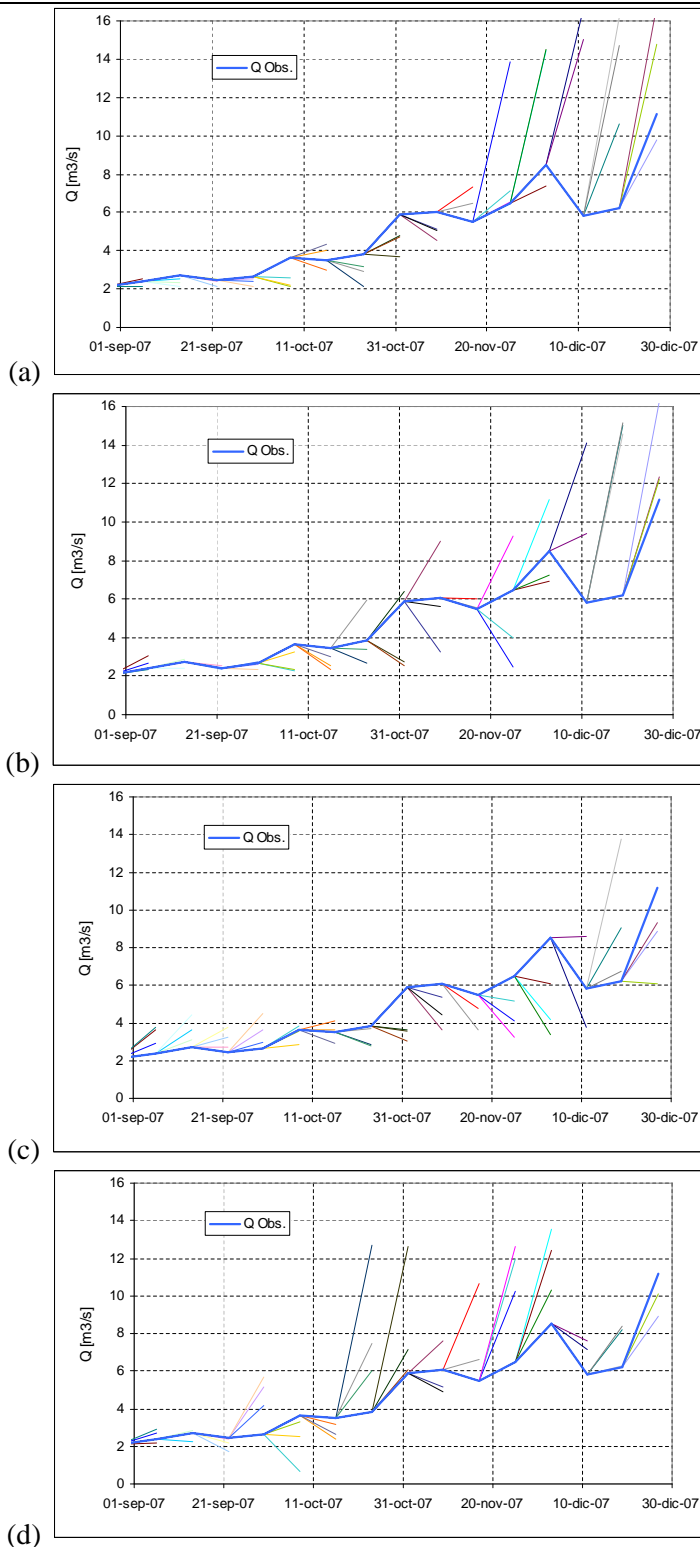


Figura 6.1. Escorrentía pronosticada con 2 intervalos de adelanto en la cuenca del río Juncal, para el período 2007-2008. Modelo para (a) 2, (b) 6, (c) 10 y (d) 20 desfases.

A partir de la Figura 6.1 se puede reconocer la variabilidad de la respuesta generada por la red neuronal para los modelos asociados a diferentes desfases de información evaluados. El pronóstico para los meses de septiembre y octubre posee una baja incertidumbre, salvo para la respuesta del modelo para 20 desfases, en la que la escorrentía de octubre y noviembre es sobreestimada significativamente.

En la Figura 6.2 se muestra el pronóstico realizado el día 1 de Septiembre, seleccionando uno de los 3 modelos calibrados para los diferentes desfases indicados anteriormente². Como se señaló, la generación de un modelo con muchos desfases sugiere la pérdida de información, pues es necesario mantener la misma longitud de las series, vale decir, tanto la serie de caudales como la serie de información de cobertura deben tener el mismo número de datos. La pérdida generalizada de información puede influir de forma negativa en la generación de un pronóstico para un período mayor en el tiempo.

Debido a que los registros de escorrentía oficiales datan hasta el mes de diciembre de 2007, se omiten comentarios respecto de la respuesta obtenida durante los meses de enero y Febrero.

Cabe destacar que la posibilidad de unir la respuesta con diferentes pronósticos, es una de las características versátiles que posee el empleo de modelos de redes neuronales.

En la Figura 6.2 se observa que la construcción de un pronóstico basado en diferentes modelos tiende a reconocer el comportamiento de la escorrentía, con fluctuaciones similares en magnitud, alcanzando valores máximos parecidos a los observados.




Figura 6.2. Escorrentía pronosticada en la cuenca del río Juncal, construida a partir de diferentes modelos entrenados para diferentes desfases.

En la Figura 6.3 se muestran las respuestas generadas por los 3 modelos entrenados para cada desfase, mientras en la Figura 6.4 se muestra el promedio de los volúmenes mensuales pronosticados por las tres respuestas y se compara con el volumen observado del mismo mes. En la Figura 6.3 se aprecia que la variabilidad de las respuestas pronosticadas por cada modelo no es significativa. Al comparar los volúmenes como un promedio de las tres respuestas, se observa que el pronóstico subestima los volúmenes de escorrentía hasta el mes de noviembre, y que los sobrestima para los meses restantes. En la Tabla 6.2 se indican los errores porcentuales a nivel mensual.

Cabe resaltar que a nivel de volumen, la diferencia entre el pronóstico mensual y lo observado es menor al 13%, desde septiembre hasta diciembre. Lo anterior representa un resultado de gran interés por cuanto representa una alternativa para la generación de pronósticos de volúmenes de deshielo con baja incertidumbre en la cuenca del río Juncal.

² Es necesario indicar que para los desfases 3, 5, 7, 9, 11, 13, 15, 17, 19 y 21 se usaron los modelos del desfase inmediatamente superior.




Figura 6.3. Escorrentía pronosticada en la cuenca del río Juncal, construida con conjuntos de modelos entrenados para diferentes desfases.




Figura 6.4. Volumen de escorrentía mensual observada v/s pronosticada, en la cuenca del río Juncal.

Tabla 6.2. Pronóstico de volúmenes de deshielo (desde el 1 de Septiembre de 2007), en la cuenca del río Juncal. Comparación de los volúmenes mensuales, generados por respuestas de modelos de diferente desfase en forma conjunta.

Meses	Sep-07	Oct-07	Nov-07	Dic-07	Ene-08	Feb-08
Vol-OBSERVADO [mill.m ³]	7.07	11.64	16.54	21.91	18.00	1.71
Vol-PRONOSTICADO [mill.m ³]	6.95	10.19	14.37	22.44	32.79	17.38
Error %	-1.75	-12.47	-13.08	2.44	82.19	915.54

En la Figura 6.5 se muestran el promedio acumulado de los volúmenes mensuales pronosticados por las tres respuestas y se compara con el volumen observado acumulado durante el período Septiembre de 2007 y Febrero de 2008. La respuesta de los modelos, apreciada de forma acumulada, sigue la misma tendencia hasta diciembre, mostrando pequeñas diferencias respecto de volumen observado. En los meses de enero y febrero el volumen pronosticado sobrepasa ampliamente al volumen observado.




Figura 6.5. Volumen de escorrentía acumulado, observado v/s pronosticado, en la cuenca del río Juncal.

En la Tabla 6.3 se indica el error porcentual de los volúmenes acumulados a nivel mensual. Se distingue que en diciembre de 2007, el error de los volúmenes acumulados es menor al 6%. Es importante señalar que el resultado al análisis de volúmenes acumulados otorga un grado de confianza de la respuesta general del modelo neuronal en la cuenca del río Juncal, sin embargo, este tipo de análisis soslaya la variabilidad en cada período que haya tenido la respuesta del modelo.

Tabla 6.3. Comparación de los volúmenes acumulados, observado y pronosticado, en la cuenca del río Juncal.

Meses	Sep-07	Oct-07	Nov-07	Dic-07	Ene-08	Feb-08
Vol.OBSERVADO [mill.m ³]	7.07	18.71	35.25	57.15	75.15	76.86
Vol.PRONOSTICADO [mill.m ³]	6.95	17.14	31.51	53.95	86.73	104.12
Error %	-1.75	-8.42	-10.60	-5.60	15.42	35.47

Los diferentes tipos de análisis realizados en la cuenca del río Juncal fueron reproducidos en las cuencas de los ríos Volcán y Maipo.

6.2.2. Estación río Volcán en Queltehues

En la Tabla 6.4 se muestra el resumen de los resultados numéricos, para desfases de 1, 2, 4, 6, 10 y 20 períodos, cuando se realiza el pronóstico desde el día 1 de Septiembre con los modelos entrenados, empleando un mismo conjunto de información de entrada (según la transecta central).

Tabla 6.4. Pronóstico de volúmenes de deshielo (desde el 1 de Septiembre de 2007), en la cuenca del río Volcán. Evaluación de modelos generados para diferentes desfases.

Desfases	1	2	4	6	10	20
Tiempo [días]	8	16	32	48	80	160
Vol.OBSERVADO [mill.m ³]	4.55	7.17	7.57	10.06	25.83	84.26
Vol.PRONOSTICADO [mill.m ³]	3.20	5.12	6.13	12.23	26.88	97.32
Error %	-29.68	-28.66	-19.08	21.50	4.07	15.50

Obs.: El volumen pronosticado corresponde al promedio de los 3 modelos utilizados en esta cuenca.

En la Figura 6.6 se muestran los resultados gráficos obtenidos para desfases de 2, 6, 10 y 20 períodos, desde el 1 de Septiembre hasta el 27 de Diciembre.

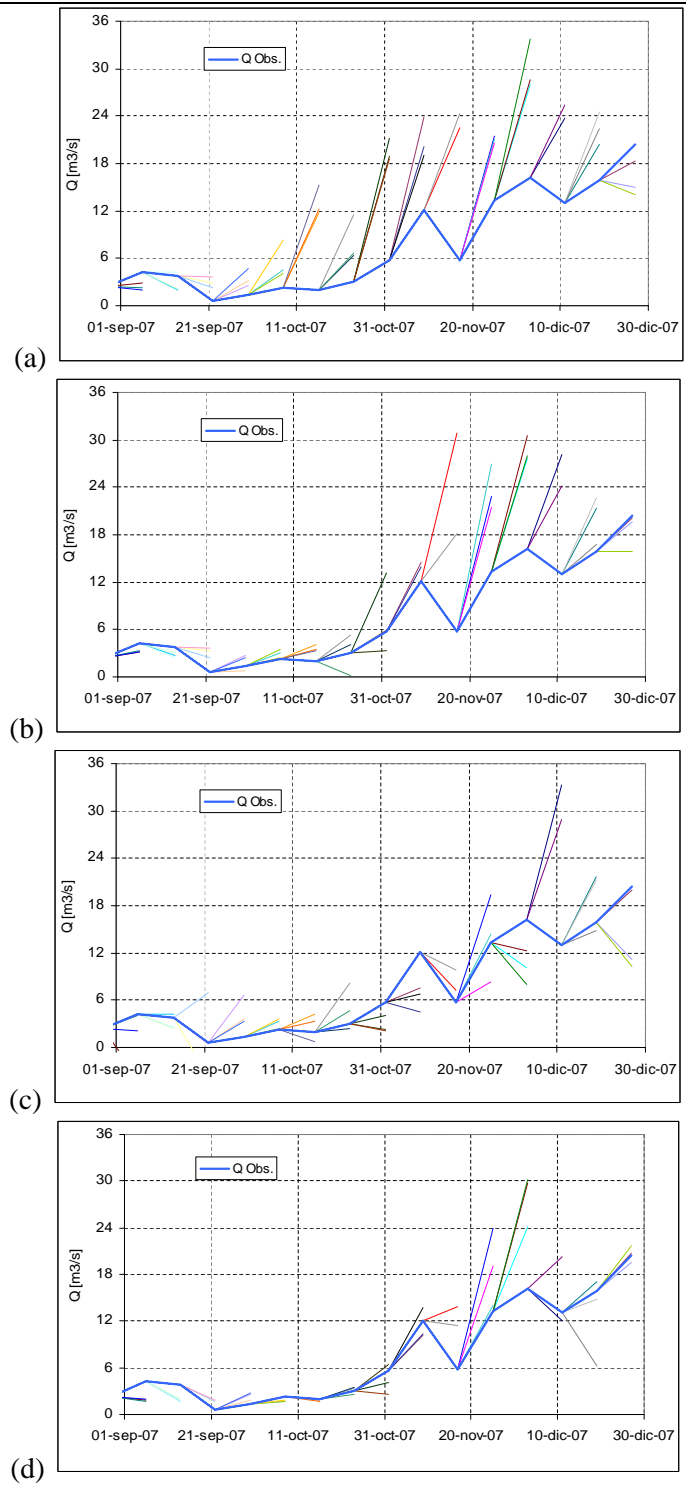


Figura 6.6. Escorrentía pronosticada con 2 intervalos de adelanto en la cuenca del río Volcán, para el período 2007-2008. Modelo para (a) 2, (b) 6, (c) 10 y (d) 20 desfases.

En la Tabla 6.4, se observa que volúmenes pronosticados poseen un error porcentual superior al 20%. Lo anterior muestra la variabilidad en la respuesta de la red neuronal en la cuenca del río Volcán, con subestimaciones y sobrestimaciones del 20% de error. Si bien, los valores numéricos de la escorrentía pronosticada son cercanos a los valores observados, se distingue la tendencia hacia una menor incertidumbre de los resultados en la medida que los desfases de la información son mayores. A partir de los resultados gráficos, se aprecia la sobreestimación de la escorrentía pronosticada

durante el mes de noviembre, lo que puede ser explicado por un período sin tormentas con una cobertura en retroceso, sujeto a una alta ablación del manto.

En la Figura 6.7 se muestra el pronóstico realizado el día 1 de Septiembre, seleccionando 1 de los 3 modelos calibrados para los diferentes desfases. En la Figura 6.8 se muestran las respuestas generadas por los tres modelos entrenados para cada desfase, mientras en la Figura 6.9 se muestra el promedio de los volúmenes mensuales pronosticados por las tres respuestas y se compara con el volumen observado del mismo mes.




Figura 6.7. Escorrentía pronosticada en la cuenca del río Volcán, construida a partir de diferentes modelos entrenados para diferentes desfases.




Figura 6.8. Escorrentía pronosticada en la cuenca del río Volcán, construida con conjuntos de modelos entrenados para diferentes desfases.

En las Figuras 6.7 y 6.8 se distingue la variabilidad de la escorrentía pronosticada, la que sigue la tendencia de la escorrentía observada, sujeta a desfases temporales de corta longitud. En particular al acentuar el análisis en la crecida del 15 de Noviembre, se observa que la red pronostica una crecida de la misma magnitud con un adelanto de 1 semana. Para la crecida máxima ocurrida durante enero, se aprecia que el pronóstico posee un retardo temporal de aproximadamente 1 mes, fenómeno que puede estar asociado a diferentes factores climatológicos. En la Figura 6.9 se destaca la subestimación del volumen

pronosticado durante el mes de diciembre. Al evaluar el volumen durante el mes de enero, es posible considerar que la diferencia de sobreestimación es comparable con la subestimación del mes de diciembre.




Figura 6.9. Volumen de escorrentía mensual observada v/s pronosticada, en la cuenca del río Volcán.

En la Tabla 6.5 se indican los errores porcentuales a nivel mensual. Se distingue que los errores porcentuales son del orden de un 30%, desde septiembre hasta enero, con sobreestimaciones y subestimaciones para los diferentes meses.

Tabla 6.5. Pronóstico de volúmenes de deshielo (desde el 1 de Septiembre de 2007), en la cuenca del río Volcán. Comparación de los volúmenes mensuales, generados por respuestas de modelos de diferente desfase en forma conjunta.

Meses	Sep-07	Oct-07	Nov-07	Dic-07	Ene-08	Feb-08
Vol-OBSERVADO [mill.m ³]	7.57	5.94	18.40	40.32	43.27	14.27
Vol-PRONOSTICADO [mill.m ³]	6.32	9.36	20.65	27.96	53.51	31.36
Error %	-16.62	57.54	12.23	-30.67	23.67	119.73

En la Figura 6.10 se muestran el promedio acumulado de los volúmenes mensuales pronosticados por las tres respuestas y se compara con el volumen observado acumulado durante el período septiembre de 2007 y febrero de 2008. La respuesta de los modelos vistas de forma acumulada sigue la misma tendencia hasta enero, mostrando pequeñas diferencias respecto del volumen observado. En el mes de febrero el volumen pronosticado sobrepasa ampliamente al volumen observado.

En la Tabla 6.6 se indica el error porcentual de los volúmenes acumulados a nivel mensual. A partir de la Tabla 6.6 se distingue que, a pesar que en los primeros meses de análisis, el error de los volúmenes acumulados es alto, la compensación durante enero permite obtener un error muy bajo, menor al 2%.

Tabla 6.6. Comparación de los volúmenes acumulados, observado y pronosticado, en la cuenca del río Volcán.

Meses	Sep-07	Oct-07	Nov-07	Dic-07	Ene-08	Feb-08
Vol-OBSERVADO [mill.m ³]	7.57	13.52	31.91	72.24	115.51	129.78
Vol-PRONOSTICADO [mill.m ³]	6.32	15.67	36.32	64.28	117.79	149.15
Error %	-16.62	15.98	13.82	-11.02	1.98	14.93




Figura 6.10. Volumen de escorrentía acumulado, observado v/s pronosticado, en la cuenca del río Volcán.

6.2.3. Estación río Maipo en Las Hualtatas

En la Tabla 6.7 se muestra el resumen de los resultados numéricos, para desfases de 1, 2, 4, 6, 10 y 20 períodos, cuando se realiza el pronóstico desde el día 1 de Septiembre con los modelos entrenados, empleando tres conjuntos de información diferentes (información de cobertura en diferentes pixeles).

Tabla 6.7. Pronóstico de volúmenes de deshielo (desde el 1 de Septiembre de 2007), en la cuenca del río Maipo. Evaluación de modelos generados para diferentes desfases.

Desfases	1	2	4	6	10	20
Tiempo [días]	8	16	32	48	80	160
Vol-OBSERVADO [mill.m ³]	15.52	24.60	32.87	53.26	113.66	272.26
Vol-PRONOSTICADO [mill.m ³]	30.28	44.35	58.62	99.06	246.18	423.82
Error %	95.11	80.31	78.36	86.00	116.60	55.67

En la Tabla 6.7, se aprecia que la sobrestimación de los volúmenes de deshielo es considerable (error >50%). Es importante destacar que los valores de ECM obtenidos en la etapa de entrenamiento y validación sugerían que el error del pronóstico sería alto, lo que es confirmado por los resultados señalados en la Tabla 6.7. Al comparar esta característica con las demás cuencas, se distingue que el tamaño de la cuenca del río Maipo es significativamente mayor, para lo cual sería necesario involucrar un mayor número de pixeles como entrada al modelo de red neuronal. En la Figura 6.11 se muestran los resultados gráficos obtenidos para desfases de 2, 6, 10 y 20 períodos, desde el 1 de Septiembre hasta el 27 de Diciembre.

La sobrestimación de la escorrentía se produce mayoritariamente al considerar desfases de tiempo pequeños, en la que la red neuronal coincide en sus diferentes respuestas, con una escorrentía pronosticada mucho mayor a la observada. En general, el pronóstico resultante para la cuenca del río Maipo puede ser considerado un caso puntual sujeto a variables no evaluadas, como es el tamaño de la cuenca, dispersión de las series de tiempo, o conformación de la cuenca desde el punto de vista geomorfológico. En particular, el modelo generado para un desfase de 20 períodos permitiría pronosticar con baja incertidumbre hasta el mes de octubre.

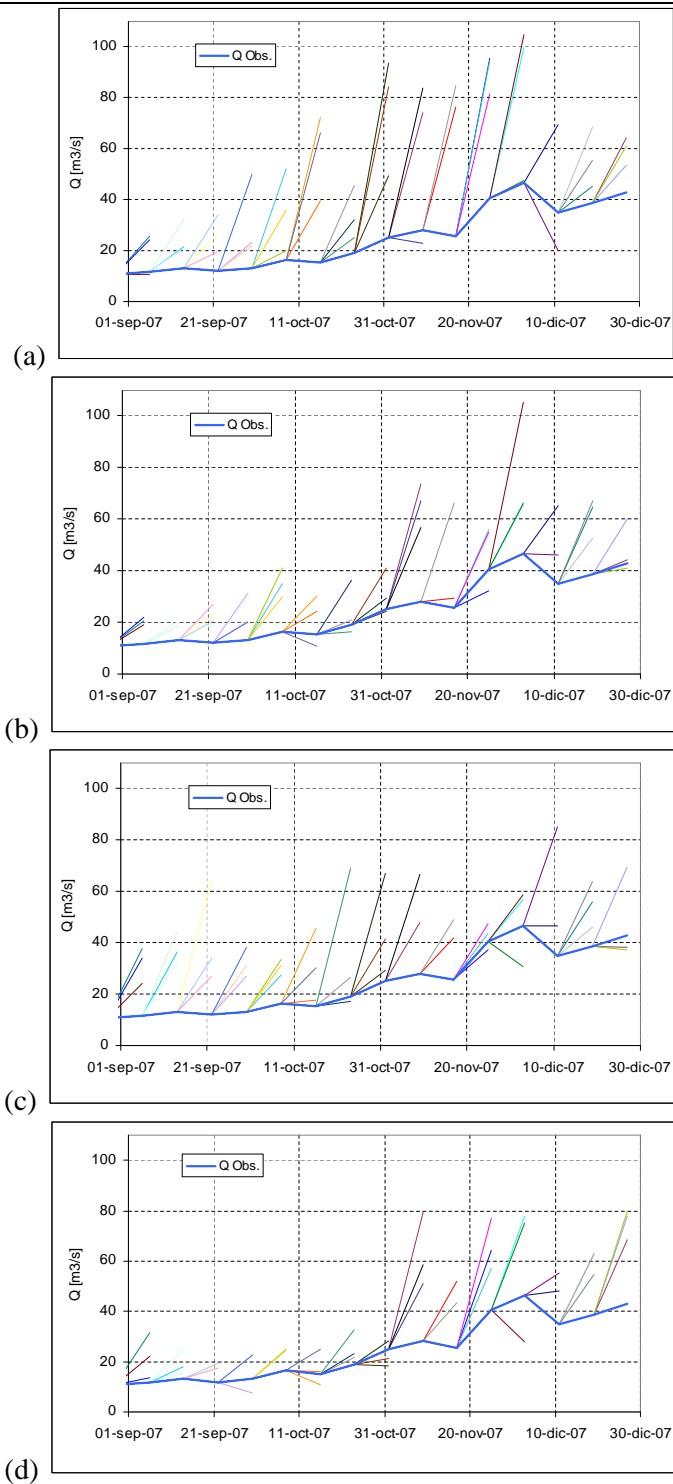


Figura 6.11. Escorrentía pronosticada con 2 intervalos de adelanto en la cuenca del río Maipo, para el período 2007-2008. Modelo para (a) 2, (b) 6, (c) 10 y (d) 20 desfases.

En la Figura 6.12 se muestra la respuesta simultánea de los diferentes modelos para diferentes desfases, construida de forma conjunta. Se aprecia que el pronóstico sigue una tendencia levemente similar a la observada, sujeto a fluctuaciones considerables, que llegan a duplicar la escorrentía observada.




Figura 6.12. Escorrentía pronosticada en la cuenca del río Maipo, construida a partir de diferentes modelos entrenados para diferentes desfases.

En la Figura 6.13 se muestran las respuestas generadas por los tres modelos entrenados por cada desfase, mientras en la Figura 6.14 se muestran los volúmenes mensuales pronosticados por las tres respuestas y se compara con el volumen observado del mismo mes. En las Figuras 6.13 y 6.14 se distingue la sobrestimación de la escorrentía pronosticada, para todo el período de análisis. Dicha sobrestimación es significativamente elevada, lo que no puede ser explicado mediante algún fenómeno climatológico en la región. En la Tabla 6.8 se indican los errores porcentuales a nivel mensual, donde se distingue que los errores porcentuales para cada mes son en promedio mayores al 60%.




Figura 6.13. Escorrentía pronosticada en la cuenca del río Maipo, construida con conjuntos de modelos entrenados para diferentes desfases.

En la Figura 6.15 se muestran el promedio acumulado de los volúmenes mensuales pronosticados por las tres respuestas y se compara con el volumen observado acumulado durante el período Septiembre de 2007 y Febrero de 2008. La respuesta de los modelos vista de forma acumulada muestra una sobrestimación sostenida del volumen pronosticado respecto del volumen observado.




Figura 6.14. Volumen de escorrentía mensual observada v/s pronosticada, en la cuenca del río Maipo.

Tabla 6.8. Pronóstico de volúmenes de deshielo (desde el 1 de Septiembre de 2007), en la cuenca del río Maipo. Comparación de los volúmenes mensuales, generados por respuestas de modelos de diferente desfase en forma conjunta.

Meses	Sep-07	Oct-07	Nov-07	Dic-07	Ene-08	Feb-08
Vol.OBSERVADO [mill.m ³]	34.48	52.33	82.59	112.72	99.51	45.28
Vol.PRONOSTICADO [mill.m ³]	59.69	85.27	140.59	150.93	179.14	85.83
Error %	73.11	62.94	70.23	33.90	80.03	89.55




Figura 6.5. Volumen de escorrentía acumulado, observado v/s pronosticado, en la cuenca del río Maipo.

En la Tabla 6.9 se indican los errores porcentuales a nivel mensual, donde se aprecia que la sobreestimación del volumen pronosticado es superior al 30% en el mes de diciembre y superior al 60% para los demás meses.

Al comparar los resultados de las tres cuencas evaluadas, se aprecia que la mejor respuesta está asociada a la cuenca de menor tamaño, en la que basta 4 series de información de cobertura de nieve para reconocer la variabilidad del fenómeno y su repercusión sobre la escorrentía de deshielo, posibilitando la

generación de un pronóstico de baja incertidumbre (error <13%, según Tabla 6.2). En la cuenca del río Volcán, los errores son mayores (error<30, según Tabla 6.5) aunque se consigue una mayor similitud en la caracterización de la crecida de deshielo sujeta a desfases temporales en el derretimiento de la nieve. En el caso del río Maipo, el tamaño de la cuenca puede afectar significativamente la respuesta de los modelos. Los resultados para este caso son desalentadores (error>60%, según Tabla 6.8) e indican la inviabilidad de emplear modelos de redes neuronales entrenados sólo con información de cobertura.

Tabla 6.9. Comparación de los volúmenes acumulados, observado y pronosticado, en la cuenca del río Maipo.

Meses	Sep-07	Oct-07	Nov-07	Dic-07	Ene-08	Feb-08
Vol.OBSERVADO [mill.m ³]	34.48	86.81	169.40	282.12	381.63	426.91
Vol.PRONOSTICADO [mill.m ³]	59.69	144.96	285.55	436.48	615.62	701.45
Error %	73.11	66.98	68.56	54.71	61.31	64.31

CAPÍTULO VII CONCLUSIONES

7.1. COMENTARIOS ACERCA DE LA INFORMACIÓN REMOTA

Los modelos hidrológicos orientados a la modelación de la escorrentía de deshielo requieren incluir información de diferente naturaleza proveniente de: estaciones meteorológicas y fluviométrica, de imágenes satelitales, y de otros modelos, que permitan la calibración de los parámetros y la validación de la respuesta de salida del modelo. En la zona cordillerana del centro de Chile las estaciones meteorológicas estatales son escasas llegando incluso a no superar las 2 unidades en la región de estudio, lo cual trae como consecuencia la inadecuada determinación de gradientes de temperatura o precipitación requeridos por algunos modelos de base física. El limitado número de estaciones tampoco permite la validación de modelos meteorológicos en la alta cordillera, lo que deja de manifiesto la incerteza en su respuesta. La información remota también requiere ser validada, sin embargo, al poseer un carácter de información medida y filtrada, representa una opción para reconocer la variabilidad del manto durante todo el año a intervalos discretos en el tiempo, sin la necesidad estricta de una validación en su empleo.

Las imágenes MODIS representan una alternativa para evaluar fenómenos que varían estacionalmente y que posean alteraciones espaciales por sobre los 250 metros. De los productos derivados de las imágenes MODIS se evaluaron 2 tipos: MODIS09 – Surface Reflectance y MODIS10 – Snow-Cover. No se utilizaron imágenes MODIS10 por dos razones:

- período de disponibilidad menor que las MODIS09 (13 de septiembre del año 2000 comparado con el 26 de febrero del año 2000), lo que representaba una limitación para el uso de un modelo de RNA,
- validación puntual de este tipo de imágenes en Chile.

Si bien, la visita a terreno realizada el 12 de Julio del 2007 permitió definir un umbral de 0.4 como indicador de la presencia de nieve asociada a una altura del manto mayor a 10 cm., los análisis realizados en torno al porcentaje de área cubierta demostraron la necesidad de elevar este umbral como diferenciador de nieve, lo cual es posible mediante el uso de MODIS09.

La selección del umbral NDSI apropiado, tanto para la determinación del área cubierta como para la eliminación o permanencia de la imagen en la serie, representa uno de los mayores problemas en este tipo de estudios. La conjunción de criterios estadísticos con aspectos remotos cualitativos-cuantitativos, representa una opción para el manejo en conjunto de este tipo de información, que además, posibilitaría la eliminación de imágenes para casos particulares. En la búsqueda de un modelo de regresión lineal entre la cobertura de nieve y la escorrentía de deshielo, se determinó, a partir de la correlación más alta entre las variables, que un umbral $NDSI = 0.7$ único durante todo el año, representaba la mejor alternativa como elemento discriminatorio, sin embargo, en la bibliografía consultada se recomienda el uso de diferentes umbrales para cada temporada. La incorporación de la topografía como elemento decisor en el umbral es un tema que queda para la discusión, puesto que tampoco se maneja una base cartográfica confiable en la alta cordillera.

El uso de matrices temporales responde a la necesidad de evaluar las alteraciones del manto de nieve desde diferentes puntos de vista. La determinación del área porcentual cubierta por nieve para las 359 imágenes, representa sin dudas un resultado de gran rendimiento para la comprensión del fenómeno en las 6 cuencas estudiadas. La generación de series temporales a partir de transectas es otra alternativa que se desprende del análisis matricial y que permite realizar un seguimiento a la evolución del manto de nieve de forma simple, al simular un testigo del manto sujeta a una variabilidad regular durante el año hidrológico.

Es importante destacar la facilidad y rapidez que existe en la generación de series temporales a nivel de píxel, transecta, o área de cobertura, una vez que se ha incluido la imagen en la matriz temporal. La actualización de la matriz por cada imagen puede significar 30 minutos, divididos en 25 minutos para la obtención de la imagen del portal web y 5 minutos en su incorporación a la matriz.

7.2. COMENTARIOS ACERCA DEL ANÁLISIS DE LA INFORMACIÓN SATELITAL

El análisis continuo de la cobertura permitió explicar diferentes elementos de la hidrología de nieves tales como: (i) desfase con la escorrentía de deshielo, (ii) área máxima y mínima de cobertura y (iii) efecto del período de acumulación sobre el volumen de escorrentía. En relación a la temperatura observada, su variación está directamente relacionada a las alteraciones en la cobertura de nieve, lo que representa una alternativa para estimar el derretimiento del manto y su aceleración en la temporada de deshielo. El desfase temporal entre el derretimiento y el volumen máximo de escorrentía alcanzado, puede ser explicado mediante flujos sub-superficiales a través de la roca en la alta cordillera. Este aspecto cobra interés en años secos cuando se prevén aportes provenientes de los hielos eternos.

Al realizar un estudio de la variabilidad espacial de la masa glaciar, se observó que la escala espacial de las imágenes no daba abasto para dicho análisis, puesto que el retroceso de la lengua glaciar no puede ser visualizado a dicha escala. Si bien, existe un retroceso importante durante las últimas décadas tanto del volumen como de la lengua glaciar, dicha disminución no es superior a 500 m por año, lo que trae como consecuencia que no es perceptible por las imágenes en un análisis anual. Se cree que este tipo de análisis sólo puede ser realizado mediante la utilización de imágenes con una mayor resolución espacial (30m o mayor), de manera de distinguir cambios a nivel anual.

Un mapa de concentración de imágenes NDSI permitirá generar un mapa de isoyetas de nieve en la medida que se consiga un mayor número de imágenes de manera que su construcción sea más representativa. Este enfoque permitirá eventualmente definir varias líneas de nieve por temporada y no una sola, como es lo que actualmente se utiliza.

7.3. COMENTARIOS ACERCA DEL MODELO

El pre y post-procesamiento de la información son etapas claves en cualquier modelo, ya sean determinísticos o estocásticos. Las 4 alternativas de selección de información remota dan cuenta de las diferentes formas en que se pueden utilizar los registros satelitales en serie agregando condiciones topográficas y de cobertura nival. De esta manera, la selección de píxeles mediante distintos criterios como información semi-distribuida es una interesante herramienta para el conocimiento parcial de la cuenca en torno a algún elemento característico.

Los resultados de la calibración indican que las redes neuronales recurrentes representan una alternativa para la modelación de la escorrentía de deshielo puesto que la información de entrada posee un carácter errático capaz de ser captado por la red. La búsqueda de una arquitectura apropiada representa un tedioso trabajo que involucra numerosas pruebas. En el presente trabajo fueron definidas múltiples características para su evaluación en las diferentes cuencas en estudio, las cuales fueron evaluadas mediante funciones objetivos universales. En la comprensión de los resultados obtenidos, durante la determinación del modelo para cada cuenca, el análisis de sensibilidad permitió distinguir al número de series de entrada y al desfase temporal entre las series remotas como aquellos elementos de mayor sensibilidad. Elementos de menor sensibilidad son el tipo de selección de información de entrada y la inclusión de la serie de porcentaje de cobertura.

La determinación de un modelo diferente para cada cuenca está asociada a las desiguales características que posee cada una, tales como tamaño, exposición solar, altitud media y latitud, entre otras.

La validación del modelo da cuenta de la inestabilidad que presentan los diferentes modelos para las diferentes cuencas producto de la información de entrada. La información de cobertura para un píxel puede tomar valores entre -1 y 1, generándose valores menores a 0.4 durante tormentas o algún otro evento, dando lugar a una serie con grandes fluctuaciones. Al entrar esta información a la red neuronal la respuesta resultante se vuelve inestable malogrando el resultado final.

Aún así, dado que la función de minimización de la red neuronal busca minimizar el error cuadrático medio, los volúmenes simulados poseen un error menor al 10% en 5 de las 6 cuencas estudiadas.

7.4. RESULTADOS DEL MODELO

El desarrollo de nuevas metodologías de estudio en el área de la hidrología de nieves permite un conocimiento más certero de los volúmenes de agua almacenados en el manto de nieve. Un entendimiento más acabado de la dinámica del manto permite no sólo una evaluación de la disponibilidad del recurso hídrico, sino que fomenta el uso racional con varios meses de antelación, permitiendo manejar elementos tales como regla de operación de embalses interanuales de manera óptima.

La modelación generada para el año hidrológico 2007-08 para una ventana de 5 meses de pronóstico da cuenta de las inestabilidades obtenidas en la etapa de validación. Los resultados obtenidos muestran una baja incertidumbre en el pronóstico mensual, para una ventana de 4 meses. La sobrestimación obtenida para el mes de enero en adelante sugiere que el pronóstico debe ser actualizado de manera de obtener una menor incertidumbre.

7.5. CONCLUSIONES GENERALES

La ciencia hidrológica requiere conocer de forma más certera los elementos que influyen o que dan como respuesta la escorrentía de deshielo. Debido a que cada región posee sus propios elementos, particularidades y características, las relaciones que se generen en una determinada región estarán acotadas a ese sub-mundo particular ordenado por relaciones propias, leyes que pueden ser parecidas a las de otras regiones pero, en la generalización existirá un grado de acierto y desacierto. Por tal motivo, al identificar una relación entre variables, ésta se desarrollará en la región específica de donde nació sin tener necesariamente, la virtud de traspasar las fronteras naturales. La variabilidad en el comportamiento de mares y continentes, puede también aplicarse a los cordones montañosos, en los que existirán muchos elementos en común, como bajas temperaturas y grandes alturas, pero el desarrollo de los fenómenos no será el mismo, lo que representa el desafío de la investigación en cada lugar del mundo. En la presente investigación se indicó la problemática en el empleo de dos relaciones particulares en el país las que son aceptadas en el mundo, lo cual constituye una ventaja en la búsqueda del entendimiento de las nieves en nuestro país. Un umbral NDSI por sobre 0.4 o diferenciado por temporada, y la relación lineal entre derretimiento y temperatura, son dos relaciones que deben ser validadas en Chile o utilizadas con cautela.

La metodología expuesta en torno al empleo de matrices históricas, generadas a partir de imágenes satelitales puede ser aplicada para el entendimiento de otros procesos naturales en la medida que exista una correspondencia entre las escalas temporales y espaciales del fenómeno y las imágenes.

El principal objetivo de este trabajo, la generación de pronósticos de volúmenes de deshielos con un error menor al 10%, no fue alcanzado debido a múltiples razones. La evaluación para un año en particular mediante este tipo de modelos es reducido por cuanto las características de dicho año pueden ser diferentes a los demás años utilizados en la generación del modelo. De esta manera, no se descarta el uso de este tipo de herramientas en el futuro, en la medida que exista un mayor número de registros satelitales o de otras fuentes de información con amplios registros temporales.

7.6. RECOMENDACIONES

Este trabajo otorga un entendimiento hacia variables como el desfase que existe entre la cobertura de nieves y la escorrentía de deshielo. La ampliación de esta relación hacia el norte y sur del país representaría una base práctica y ordenada para un conocimiento diferenciado a lo largo del país, que permitiría abordar el problema de la modelación enfocado a las características de cada zona y con diferentes escalas temporales si fuese necesario. La generación de un mapa de Chile en torno a la altura de nieves, resultante como concentración de mapas de cobertura, vale decir, a partir del acoplamiento de un conjunto de imágenes con filtro NDSI, es otro alcance de interés para desarrollar en trabajos futuros de manera de actualizar la información existente a la fecha.

Durante el presente año, la base de imágenes MODIS10 fue ampliada al 26 de Febrero del año 2000, lo cual representa una alternativa para su uso al encontrarse a iguales condiciones de disponibilidad que las imágenes MODIS09. Dadas las características particulares de este tipo de imágenes, que indica región con/sin nieve se recomienda realizar validaciones en diferentes puntos del país.

Los resultados obtenidos en torno a la modelación mediante técnicas artificiales sugieren un trabajo en torno a la búsqueda de planteamientos alternativos para el empleo de información remota filtrada mediante procesos más elaborados que otorguen una mayor estabilidad de las señales vistas individualmente.

CAPÍTULO VIII

REFERENCIAS

- ACEITUNO, P., Fuenzalida, H., Rosenbluth, B. (1992). Climate along the extratropical West coast of South America. Pp. 61-69 en *Earth Systems responses to global change* (Eds. H.A. Mooney, B. Kronberg and E.R. Fuentes), Academic Press.
- AUSEEM, A., Murtagh, F., Sarazin, M. (1995). Dynamical recurrent neural networks- toward environmental time series prediction. *International Journal on Neural System*, Vol. 6, pp: 145-170.
- AYAZ, E., Sever, S., Barutcu, B., Türkcan, E. (2003). Comparisons between the various types of neural networks with the data of wide range operational conditions of the borssele NPP. *Progress in Nuclear Energy*, Vol. 43, No. 1-4, pp:381-387.
- BISHOP, C. M. (1995) *Neural Networks for Pattern Recognition*. Oxford University Press.
- BROWN, E. (2007). “Comunicación Personal”.
- CADE-IDEPE, Consultores en Ingeniería. (2004). Diagnóstico y clasificación de los cursos y cuerpos de agua según objetivos de calidad, Cuenca del Río Aconcagua.
- CHOI, H., Bindschadler, R. (2004). Cloud detection in Landsat of ice sheets using shadow matching technique and automatic normalized difference snow index threshold value decision. *Remote Sensing of Environment*, 91, 237-242.
- CHOW V. T., Maidment D., Mays L. (1994). *Hidrología Aplicada*. McGraw-Hill
- CONNOR, J. T., Douglas, R. D., Atlas, L. E. (1994). Recurrent neural networks and robust time series prediction. *IEEE Transaction on Neural Networks*, Vol. 5, N° 2, pp: 240-254.
- DGF/UCH, CONAMA (2006). Estudio de la Variabilidad Climática en Chile para el siglo XXI.
- DOZIER, J. (1989). Spectral signature of alpine snow cover from the Landsat Thematic Mapper. *Remote Sensing of Environment*, 28, 9–22.
- DROSSU, R., Obradovic, Z., Fletcher, J. (1996). A flexible graphical user interface for embedding heterogeneous neural network simulators. *IEEE Transactions on Education*, Vol. 39, N° 3, pp: 367–374.
- DUNNE, T. and Black, R. D. (1971). Runoff processes during snowmelt. *Water Resources Research*, Vol. 7, No. 5, pp: 1160-1171.
- EARTH OBSERVING SYSTEM DATA GATEWAY (EDG). National Aeronautics and Space Administration (NASA). <http://edcimswww.cr.usgs.gov/pub/imswelcome>
- ELMAN, J. L. (1990). Finding structure in time. *Cognitive Science*, No. 14 pp:179-211.
- ESTEVEZ, P. (2007). “Comunicación personal”.
- HALL, D.K. and MARTINEC, J. (1985) *Remote sensing of ice and snow*. Chapman & Hall, London.

- HALL, D. K., Foster, J. L., and Chang, A. T. C. (1992). Reflectance of snow as measured in situ and from space in sub-arctic areas in Canada and Alaska. *IEEE Transactions on Geoscience and Remote Sensing*, 30(3), 634–637.
- HALL, D. K., Riggs, G. A., and Salomonson, V. V. (1995). Development of methods for mapping global snow cover using Moderate Resolution Imaging Spectroradiometer (MODIS) data. *Remote Sensing of Environment*, 54, 127-140.
- HALL, D. K., Riggs, G. A., Salomonson, V. V., DiGirolamo N. E. and Bayr, K. J. (2002). MODIS snow-cover products. *Remote Sensing of Environment*, 83, 181-194.
- HALL, D. K. and Riggs, G. A. (2006). Accuracy assessment of the MODIS snow products. *Hydrological Processes*, 21, 1534-1547.
- HARRINGTON, R. and Bales, R. (1998). Interannual, seasonal, and spatial patterns of meltwater and solute fluxes in a seasonal snowpack. *Water Resources Research*, Vol. 34, No. 4 pp: 823–831
- GUPTA, R., Haritashya, U., Singh, P. (2005). Mapping dry/wet snow cover in the Indian Himalayas using IRS multiespectral imagery. *Remote Sensing of Environment*, 97, 258–269.
- KANE, D.L. and Chacho, E.F. (1990). Frozen ground effects on infiltration and runoff. in Cold Regions Hydrology and Hydraulics eds. *W.L. Ryan and R.D. Crissman pp:259-300. ASCE, New York.*
- KANE, D.L. and Stein, J. (1983). Water movement into seasonally frozen soils. *Water Resources Research*, Vol. 19, No. 6, pp: 1547-1557.
- KLEIN, A. and Barnett, A. (2003). Validation of daily MODIS snow cover maps of the Upper Rio Grande River Basin for the 2000-2001 snow year. *Remote Sensing and Environment*, 86, 162-176.
- MAURER, AE., Rhoads, J., Dubayah, R., Lettenmaier, D. (2003) Evaluation of the snow-covered area data product from MODIS. *Hydrological Processes*, 17, 59-71.
- MENDENHALL, W and Sincich, T. (1997). *Statistic for engineering and the sciences*. 4^o Edition, Publisher Prentice-Hall, Inc.
- MODIS Web. National Aeronautics and Space Administration (NASA). <http://modis.gsfc.nasa.gov>
- MODIS Land Surface Reflectance, Science Computing Facility. National Aeronautics and Space Administration (NASA). <http://modis-sr.ltdri.org>.
- MOLOTCH, N.P., Fassnacht, S.R., Bales, R.C. and Helfrich, S.R. (2004). Estimating the distribution of snow water equivalent and snow extent beneath cloud in the Salt-Verde River basin, Arizona. *Hydrological Processes*, 18, 1595-1611.
- MUÑOZ, F. (1986). Determinación de Caudales Medios Diarios efluentes de cuencas Nivo-Pluviales Andinas chilenas mediante el uso de Imágenes Satelitarias, Variables Meteorológicas y Parmámetros Hidrogeomorfológicos. Memoria para optar al Título de Ingeniero Civil. Facultad de Ciencias Físicas y Matemáticas. Departamento de Ingeniería Civil. Universidad de Chile. Santiago. Chile.
- NAKAWO, M. and Hayakawa, N. (1998). *Snow and Ice Science in Hydrology*. Institute for Hydropheric-Atmospheric Sciences, Nagoya University and United Nations Educational Scientific Organization.

NASA, NIMA, DLR, ASI. (2002). National Aeronautics and Space Administration (NASA), National Imagery and Mapping Agency (NIMA), German Aerospace Center (DLR), Italian Space Agency (ASI). Shuttle Radar Topography Mission (SRTM) Elevation Dataset. U.S. Geological Survey. Sioux Falls, SD. EE.UU. <http://seamless.usgs.gov>

NOLIN, A. W and Dozier, J. (2000). A Hyperspectral Method for Remotely Sensing the Grain Size of Snow. *Remote Sensing of Environment*, 74, 207-216.

PAINTHER, T. H and Dozier, J. (2004). The effect of anisotropic reflectance on imaging spectroscopy of snow properties. *Remote Sensing of Environment*, 89, 409-422.

PÉREZ, J. P. (2002). Predicción de Variables Meteorológicas relevantes en Radioastronomía mediante Redes Neuronales y Método Estadísticos. Memoria para optar al Título de Ingeniero Civil. Facultad de Ciencias Físicas y Matemáticas. Departamento de Ingeniería Eléctrica. Universidad de Chile.

RIGGS, G. A., Hall, D. K., and Salomonson, V. V. (1994). A snow index for the Landsar Thematic Mapper and Moderate Resolution Imaging Spectroradiometer. *Proceeding of the International Geoscience and Remote Sensing Symposium, IGARSS'94*, 8-12 August 1994. Pasadema, CA, pp, 1942-1944.

SALOMONSON, V. and Appel, I. (2004). Estimating fractional snow cover from MODIS using the normalized difference snow index. *Remote Sensing and Environmet*, 89,351-360.

SEMADENI-DAVIES, A. and Bengtsson, L. (2000). Snow and snowmelt. In Sægrov, S, Milina, J and Thorolfsson, S.T. (Eds) Urban Drainage in Cold Climates. Urban Drainage in Specific Climates, C. Maksimovic (Chief Ed.) *UNESCO IHP-V / Technical Documents in Hydrology No. 40, Vol. II, pp:41-70*

SHANLEY, J.B. and Chalmers, A. (1999). The effect of frozen soil on snowmelt runoff at Sleepers River, Vermont. *Hydrological Processes*, 13:1843-1858

SHI, J. and Dozier, J. (1997). Mapping Seasonal Snow Cover with SIR-C/X-SAR in Mountainous Areas. *Remote Sensing of Environment*, 59,294–307

SIMIC, A., Fernandes, R., Brown, R., Romanov, P., Park, W. (2004). Validation of VEGETATION, MODIS, and GOES+SSM/I snow-cover products over Canada based on surface snow depth observations. *Hydrological Processes*, 18, 1089-1104.

STROEVE, J., Box., J., Haran, T. (2006). Evaluation of the MODIS (MOD10A1) daily snow albedo product over the Greenland ice sheet. *Remote Sensing and Environment*, 105, 155-171.

TARBLE, R. D. (1963). Areal distribution of snow as determined from satellite photographs. *International Association of Hydrological Sciences Special Publication*, 65, 372-375.

TEKELI, AE., Şensoy, A., Şorman, A., Akyürek, Z., Şorman, Ü. (2006). Accuracy assessment of MODIS daily snow albedo retrievals with in situ measurements in Karasu basin, Turkey. *Hydrological Processes*, 20, 705-721.

U.S. ARMY CORPS OF ENGINEERS. (1956). “Snow Hydrology”. North Pacific Division, Portland, Oregon, EE.UU.

VALCK, P. (2004). Modelación espacial de la cobertura nival usando distribuciones de precipitaciones de modelos meteorológicos. Tesis para optar al Grado de Magíster en Ciencias de la Ingeniería, Mención Recursos y Medio Ambiente Hídrico. Memoria para optar al Título de Ingeniero Civil. Facultad de Ciencias Físicas y Matemáticas. Departamento de Ingeniería Civil. Universidad de Chile.

VALCK, P., Vargas X., Cartes M. (2006). Modelación distribuida de la cobertura nival para el pronóstico de volúmenes de deshielo. *International Association of Hydrological Sciences (IAHS). Publication, 308, 244-249.*

VERMOTE E. F., and Vermeulen, A. (1999). Atmospheric Correction Algorithm: Spectral Reflectances (MOD09). Algorithm Technical Background Document. NASA - University of Maryland, Dept of Geography.

VIKHAMAR D., Solberg R. (2003). Snow-cover mapping in forest by constrained linear spectral unmixing of MODIS data. *Remote Sensing of Environment, 88,309–323.*

WAN, E. A. (1993). Finite Impulse Response Neural Networks with Applications in Time Series Prediction. *Thesis for the degree of Doctor of Philosophy, Stanford University.*

WILLIAMS, P.J. and Smith, M.W. (1989). The Frozen Earth: Fundamentals of Geocryology. *Cambridge University Press, UK.*

WARREN, S. G., and Wiscombe, W. J. (1980). A model for the spectral albedo of snow. II: Snow containing atmospheric aerosols. *Journal of Atmospheric Science, 37, 2734–2745.*

WIGMOSTA, M. S., Vail L. W. y Lettenmaier, D.P. (1994). A Distributed Hydrology-Vegetation Model for Complex Terrain. *Water Resources Research, 30(6): 1665-1679.*

WISCOMBE, W. J., Warren, S.G. (1980). A model for the spectral albedo of snow, I. Pure snow. *Journal of the Atmospheric Sciences, Vol. 37, pp: 2712-2733.*

WMO (1986). Intercomparisons of Models of Snowmelt Runoff. *Operational Hydrology Report No. 23 (WMO-No. 646) World Meteorological Organization, Geneva.*

WMO (1992). Snow Cover Measurements and Areal Assessment of Precipitation and Soil Moisture. Sevruk, B. (Ed.) *Operational Hydrology Report No. 35 (WMO-No. 749) World Meteorological Organization, Geneva.*

ANEXOS

**ANEXO I
VALIDACIÓN PUNTUAL DE LAS IMÁGENES**

9.1. CAMPAÑAS DE TERRENO

Los recursos limitados de capital y tiempo llevaron a realizar sólo una campaña de muestreo que permite validar la imagen correspondiente al 12 de Julio (N°193, según calendario juliano) del año 2007. La actividad de terreno fue realizada el día 07 de Julio, desde las 10:00a.m., hasta las 15:00p.m., en la localidad “Camino a Farellones”, comuna de Lo Barnechea, Santiago, Región Metropolitana. Los resultados de la visita se muestran en la Tabla 9.1.

Tabla 9.1. Muestreo para la validación de cobertura de nieves.

Punto	Coordenadas		Elevación	Con/Sin Nieve	Observaciones
	UTM Norte	UTM Este			
1	6.306.735	365.540	920	Sin	-
2	6.307.007	368.129	1058	Sin	-
3	6.306.575	369.593	1081	Sin	-
4	6.307.785	371.514	1105	Sin	Existe algo de helada en la zona, existencia de cubierta de hielo, 11:11am
5	6.309.585	373.187	1238	Sin	Intersección camino Disputada-Farellones, manchones aislados de hielo
6	6.309.509	373.462	1370	Sin	Manchones aislados de hielo (Figura 9.1)
7	6.309.280	374.100	1500	Sin	Manchones aislados de hielo
8	6.310.507	375.932	1666	Con	Entrada Yerba Loca, Nieve pobre de mala calidad en manchones aislados (Figura 9.2)
9	6.309.436	376.074	1742	Con	Pasado puente el Manzano, Nieve pobre, manto < a 1 cm
10	6.308.274	376.789	2159	Con	Manto >10 cm, árboles nevados, con algunos sectores con nieve pobre. Ladera S está desprovista de nieve
11	6.309.792	379.070	2511	Con	Manto >20 cm.
12	6.309.283	379.429	2633	Con	Manto >20 cm, existencia de balnearios alrededor.
13	6.309.670	379.899	2730	Con	Manto >30 cm, costado hotel.
14	6.309.147	378.284	2431	Con	Manto >10 cm, Farellones en pleno.

Es importante mencionar que durante el día de terreno, las condiciones climáticas eran estables con cielo totalmente despejado. En la Figura 9.1 se muestra el estado de la cubierta de nieve en algunos puntos descritos en la Tabla 9.1.



Figura 9.1. (a) Restos de nieve sobre una roca (Punto N°6). (b) Yerba Loca. Nieve de mala calidad o pobre. (Punto N°8). (c) Ladera con Nieve pobre (Punto N°9). (d) Manto de nieve sobre los 5 cm. de espesor (Punto N°10). (e) Existencia de un manto de buena calidad (Punto N°11). (f) Manto de nieve de espesor mayor a 20 cm. (Punto N°13).

9.2. COMPARACIÓN CON IMAGEN

Para comprender la información obtenida mediante la imagen satelital, ésta debe ser contrastada con las mediciones realizadas. La imagen utilizada para este propósito corresponde a la MODIS surface reflectance del día 193 (MOD09-193). El contraste de la información recopilada en terreno con la imagen satelital se muestra en la Figura 9.2 y es detallada en la Tabla 9.2.

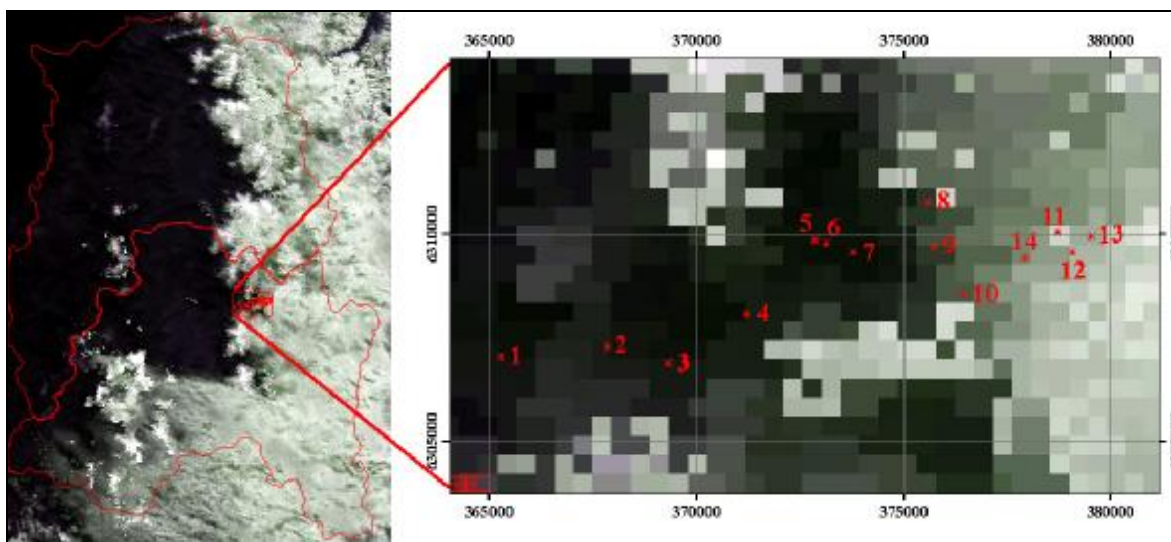


Figura 9.2. Puntos de muestreo sobre la imagen satelital MOD09-193 en color real (RGB). La nieve se distingue en aquellos píxeles de color blanco y la nieve de mala calidad se distingue en aquellos píxeles de tonalidades claras.

En la comparación de los resultados observados se aprecian diferencias, las cuales están sujetas a la percepción del experto (Mauricio Cartes). Las dos apreciaciones (terreno v/s imagen RGB) son iguales cuando existe un manto con un espesor mayor a los 20 cm. Por el contrario, cuando el manto posee un espesor menor, este no es apreciable en la imagen (Tabla 9.2). En la Figura 9.3 se aprecian los puntos de la zona de muestreo en la imagen MOD09 con aplicación del filtro NDSI (MOD09-193-NDSI).

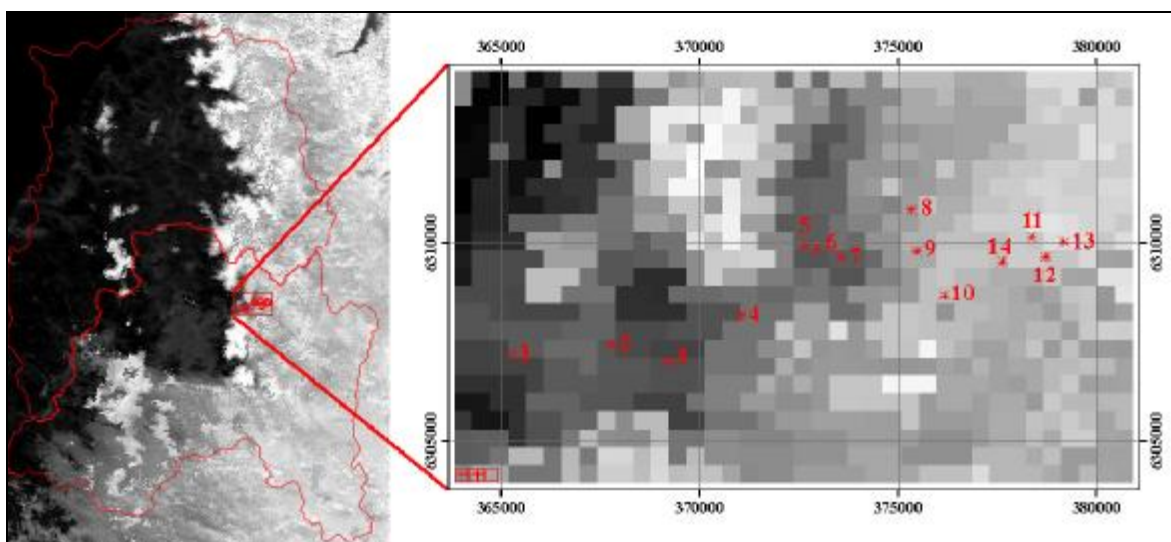


Figura 9.3. Puntos de muestreo sobre la imagen satelital MOD09-193 con aplicación del filtro NDSI. La calidad de la nieve será mejor en la media que el píxel presente una tonalidad más blanca.

Mediante esta caracterización se observa claramente una zona de transición entre los Punto N° 8 y 9, en la que los Puntos N° 10, 11, 12, 13, y 14 pueden ser agrupados en un conjunto de características similares.

En la Tabla 9.2 se aprecia también el valor del índice NDSI obtenido de la imagen utilizando las bandas 4 y 6. Al comparar con los resultados medidos en terreno se distingue que para espesores del manto mayores a 10 cm, el umbral es mayor a 0,4, lo que permite argumentar la validez de este umbral como suficiente en la diferenciación de la cubierta de nieve durante la época de acumulación de nieves.

Tabla 9.2. Comparación de muestreo de terreno con imagen MOD09-193

Punto	Terreno		Imagen RGB		NDSI
	Nieve	Observaciones	Nieve	Observaciones	
1	Sin	-	Sin	No hay nieve alrededor del punto.	-0,11
2	Sin	-	Sin	No hay nieve alrededor del punto.	-0,13
3	Sin	-	Sin	No hay nieve alrededor del punto.	-0,16
4	Sin	Existe algo de helada en la zona, existencia de cubierta de hielo, 11:11 am	Sin	Existe nieve hacia el sur este del punto.	0,01
5	Sin	Intersección camino Disputada-Farellones, manchones aislados de hielo	Sin	No hay nieve alrededor del punto.	-0,09
6	Sin	Manchones aislados de hielo	Sin	No hay nieve alrededor del punto.	-0,09
7	Sin	Manchones aislados de hielo	Sin	No hay nieve alrededor del punto.	-0,10
8	Con	Entrada Yerba Loca, Nieve pobre de mala calidad en manchones aislados	Sin	Puede haber existencia de nieve, pero de mala calidad.	0,26
9	Con	Pasado puente el Manzano, Nieve pobre, manto < a 1 cm	Sin	Puede haber existencia de nieve, pero de mala calidad.	0,33
10	Con	Manto >10 cm, árboles nevados, con algunos sectores con nieve pobre. Ladera S está desprovista de nieve	Sin	Puede haber existencia de nieve, pero de mala calidad.	0,44
11	Con	Manto >20 cm.	Con	Nieve de buena calidad.	0,48
12	Con	Manto >20 cm, existencia de balnearios alrededor.	Con	Nieve de mediana calidad.	0,48
13	Con	Manto >30 cm, costado hotel.	Con	Nieve de mediana calidad.	0,61
14	Con	Manto >10 cm, Farellones en pleno.	Sin	Puede haber existencia de nieve, pero de mala calidad.	0,44

ANEXO II
PREPROCESAMIENTO DE LAS IMÁGENES MODIS MOD09

10.1. OBTENCIÓN DE LAS IMÁGENES

Las imágenes pueden ser bajadas de forma gratuita desde el sitio en internet: <http://edcimswww.cr.usgs.gov/pub/imswelcome/>. Se recomienda generar una cuenta de nuevo usuario de manera de guardar la configuración de la última visita.

En primer lugar, se deberá seleccionar el tipo de imagen en la opción LAND. En este trabajo se utilizaron:

- *MODIS/Aqua => "MODIS/AQUA SURFACE REFLECTANCE 8-DAY L3 GLOBAL 500M SIN GRID V003"*
- *MODIS/Terra => "MODIS/TERRA SURFACE REFLECTANCE 8-DAY L3 GLOBAL 500M ISIN GRID V003"*

Luego, se debe seleccionar los límites de la región y las fechas límites para obtener el paquete de imágenes.

En este trabajo se consideró la zona delimitada por: 32°N - 38°S - 69°E - 71°O

La fecha de las imágenes se encuentra registrada de acuerdo al calendario juliano. El registro completo de las imágenes utilizadas en este trabajo se muestra en la Tabla 10.1. Como las imágenes se obtienen desde un sitio "ftp" de alto almacenamiento, la velocidad de transferencia de información dependerá de la velocidad de transferencia de Internet, proceso que puede tardar varias horas. Es por ello que se recomienda bajar sólo 30 imágenes como máximo por paquete.

Tabla 10.1. Registro de Imágenes utilizadas, de acuerdo al calendario juliano.

Fecha	Año															
	2000		2001		2002		2003		2004		2005		2006		2007	
1-ENE / 4-JUL	-	185	1	185	1	185	1	185	1	185	1	185	1	185	1	185
9-ENE / 12-JUL	-	193	9	193	9	193	9	193	9	193	9	193	9	193	9	193
17-ENE / 20-JUL	-	201	17	201	17	201	17	201	17	201	17	201	17	201	17	201
25-ENE / 28-JUL	-	209	25	209	25	209	25	209	25	209	25	209	25	209	25	209
2-FEB / 5-AGO	-	217	33	217	33	217	33	217	33	217	33	217	33	217	33	217
10-FEB / 13-AGO	-	225	41	225	41	225	41	225	41	225	41	225	41	225	41	225
18-FEB / 21-AGO	-	233	49	233	49	233	49	233	49	233	49	233	49	233	49	233
26-FEB / 29-AGO	57	241	57	241	57	241	57	241	57	241	57	241	57	241	57	241
6-MAR / 6-SEP	65	249	65	249	65	249	65	249	65	249	65	249	65	249	65	249
14-MAR / 14-SEP	73	257	73	257	73	257	73	257	73	257	73	257	73	257	73	257
22-MAR / 22-SEP	81	265	81	265	81	265	81	265	81	265	81	265	81	265	81	265
30-MAR / 30-SEP	89	273	89	273	89	273	89	273	89	273	89	273	89	273	89	273
7-ABR / 8-OCT	97	281	97	281	97	281	97	281	97	281	97	281	97	281	97	281
15-ABR / 16-OCT	105	289	105	289	105	289	105	289	105	289	105	289	105	289	105	289
23-ABR / 24-OCT	113	297	113	297	113	297	113	297	113	297	113	297	113	297	113	297
1-MAY / 1-NOV	121	305	121	305	121	305	121	305	121	305	121	305	121	305	121	305
9-MAY / 9-NOV	129	313	-	313	129	313	129	313	129	313	129	313	129	313	129	313
17-MAY / 17-NOV	137	321	137	321	137	321	137	321	137	321	137	321	137	321	137	321
25-MAY / 25-NOV	145	329	145	329	145	329	145	329	145	329	145	329	145	329	145	329
2-JUN / 3-DIC	153	337	153	337	153	337	153	337	153	337	153	337	153	337	153	337
10-JUN / 11-DIC	161	345	161	345	161	345	161	345	161	345	161	345	161	345	161	345
18-JUN / 19-DIC	169	353	-	353	169	353	169	353	169	353	169	353	169	353	169	353
26-JUN / 27-DIC	177	361	177	361	177	361	177	361	177	361	177	361	177	361	177	361
Total Imágenes	39		44		46		46		46		46		46		46	

Obs.: (-) Sin registro de imágenes

10.2. CAMBIO DE PROYECCIÓN Y RECORTE DE CADA IMAGEN

Cada imagen georreferenciada debe ser alterada en su proyección (de coordenadas Geográficas a coordenadas UTM) y luego debe ser recortada de acuerdo a los límites de la zona de estudio. En este caso corresponden a las 6 cuencas en estudio.

Estas alteraciones a la imagen inicial pueden ser llevadas a cabo utilizando el software ENVI 4.2, el cual reconoce la georreferenciación inicial de la imagen. La imagen puede ser vista en colores verdaderos (true colours) mediante la selección de las bandas 1-4-3 para R-G-B en MODIS respectivamente.




Fig 10.1. Comparación de imagen recortada y no recortada. . (Izq) Vista de Imagen inicial sin alteraciones en coordenadas Geográficas). (Der) Vista de Imagen en coordenadas UTM y recortada de acuerdo a los límites de trabajo.

Para rotar la imagen de acuerdo a la proyección común de la zona de estudio, se debe seleccionar la opción: MAP => “Convert Map Projection Input Image”, luego seleccionar la imagen para este cambio. Aparecerá una nueva ventana donde se deberá cambiar la proyección seleccionando “Change Proj...”.

En este trabajo se utilizó:

Projection: UTM

Datum: WGS-84

Zone: 18 – S

Luego “OK”, elegir la ubicación del archivo de salida y “OK”

Para recortar la imagen, se debe ir a: BASIC TOOLS => “Resize Data (Spatial/Spectral)” y seleccionar la imagen a recortar. Luego seleccionar “Spatial Subset” y elegir los límites de la región de estudio.

En este trabajo se utilizó:

cols: (samples) 1210 a 1720 (Total: 511 cols)

rows: (line) 480 a 1922 (Total: 1443 rows)

Luego “OK”, elegir la ubicación del archivo de salida y “OK”

Estos procesos pueden ser realizados en serie de forma independiente (primero cambio de proyección y luego recorte), de manera de acelerar esta etapa. Para ello se debe seleccionar la opción “queue”. Luego, se debe ir a: FILE => “ENVI Queue Manager”, y seleccionar los procesos a ejecutar y “Select all”.

10.3. GENERACIÓN IMAGEN NDSI Y B4

De manera de poder trabajar con información específica de cada imagen, como lo es la cubierta de nieve (NDSI) o una banda en particular (B4) en progresión o serie de tiempo, es necesario generar una matriz la cual estará constituida por el conjunto de imágenes. En dicha matriz, como se observa en la Figura 10.2, el eje x está orientado de acuerdo a la latitud según W-E, el eje y está orientado de acuerdo a la longitud según S-N, y el eje z corresponderá al eje del tiempo. Dicha matriz será trabajada mediante el software Matlab.

Para la generación de una imagen NDSI es necesario trabajar la imagen mediante álgebra de bandas, lo que permitirá obtener como resultado una imagen en la que el valor de cada píxel indicará el valor asociado NDSI, valor comprendido entre -1 y 1. Mediante el uso del software ENVI, se debe seleccionar la opción: BASIC TOOLS => “Band Math” y escribir la expresión general del NDSI: $(B4-B6)/(B4+B6)$. Luego “Add to List” y “Ok”.

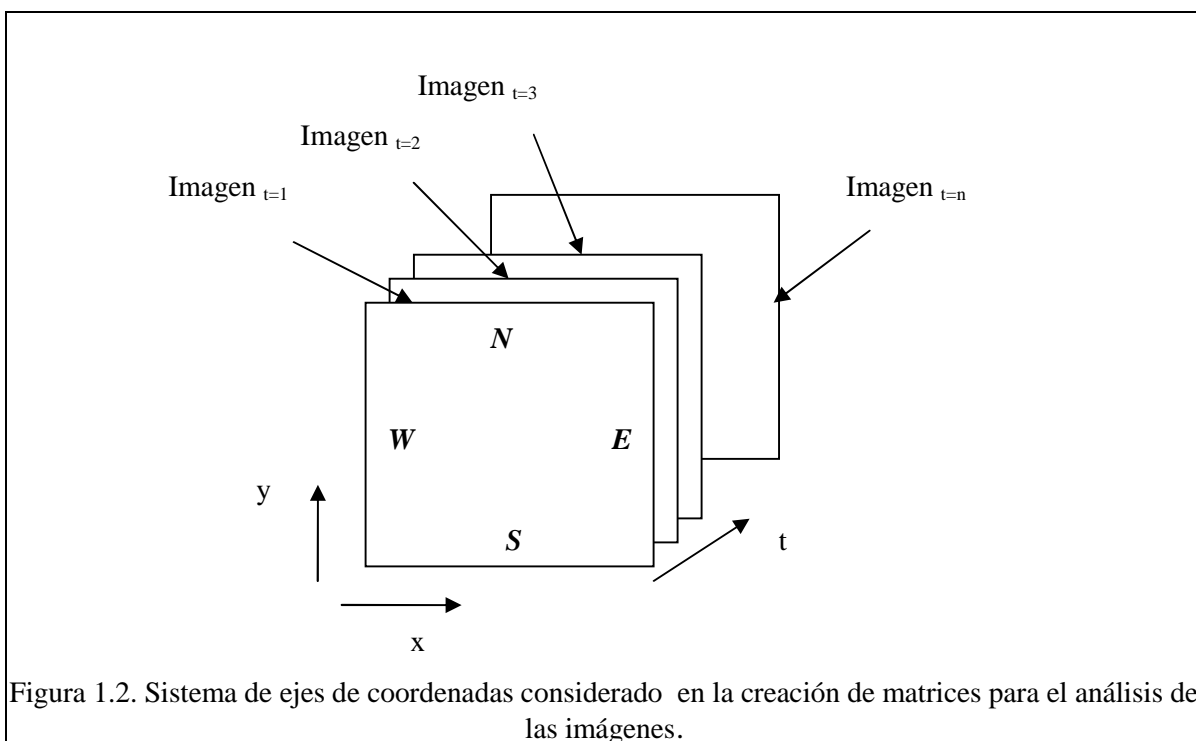


Figura 1.2. Sistema de ejes de coordenadas considerado en la creación de matrices para el análisis de las imágenes.

En la pantalla siguiente se deben elegir las bandas a las cuales se hará referencia la operación matricial. Luego, elegir la ubicación del archivo de salida y “OK”.

Se recomienda guardar los resultados en “Memory”, puesto que la información final debe ser guardada en un formato idóneo que dependerá de otras posibilidades de lecturas por otros softwares. En este trabajo se utilizará MatLab, para lo cual es necesario generar archivos que serán guardados con una extensión que pueda ser abierto por este programa. El formato elegido corresponde al formato “ASCII” (extensión “.txt”), y puede usarse para los archivos NDSI como para la banda B4.

10.4. GENERACIÓN DE MATRICES O IMÁGENES EN SERIE DE TIEMPO

Una vez generado la serie de archivos correspondientes a cada imagen, se cargarán en MatLab. Se recomienda hacerlo por grupos anuales, pues el proceso implica abrir los archivos uno a uno, para lo cual se emplea bastante memoria. Luego, los archivos serán guardados en una matriz en formato “Binario” (extensión “.bin”), lo cual representa enormes ventajas para su trabajo.

Este proceso puede ser realizado mediante el uso de la función “GeneraGranMatriz.mat”, en la que se deben especificar uno a uno los archivos “.txt” que serán abiertos, almacenados en una matriz, y luego se cerrará la lectura del archivo.

Es importante destacar que los archivos ASCII pueden tener valores no definidos (novalue), los cuales son el resultado de una división por 0 en la aplicación del álgebra de bandas u otra razón particular. Estos valores en MatLab no pueden ser leídos, por lo que se recomienda modificarlos por “NaN” (Not a Number) con algún programa simple. Se recomienda el empleo de VisualBasic o uno similar.

10.5. DERIVACIÓN DE MATRICES-CUENCA MEDIANTE APLICACIÓN DE MÁSCARA

Una vez generadas las matrices anuales o para un período en particular, es posible trabajar ciertas zonas de ella, como es el caso de una cuenca hidrográfica.

Para este proceso es necesario definir una máscara que será aplicada sobre las imágenes. Esta nueva matriz quedará definida por valores iguales a 0 y 1 donde la zona fuera del límite de la cuenca tomará el valor 0 en tanto que el área dentro tomará el valor unitario. De esta manera se busca multiplicar las matrices por esta nueva matriz-máscara, la cual generará una matriz 3-D en la que sólo existirá información en la región de interés.

Para generar la máscara es necesario trabajar sobre la topografía de la región. Para este procedimiento se recomienda el uso del Software WMS, el cual permite identificar la hoya hidrográfica definida a partir del punto de salida de la cuenca. El archivo a generar debe ser guardado mediante la opción “Shapefile” (extensión “.shp), el cual estará georreferenciado.

Luego, mediante el software ENVI, el archivo “.shp” podrá ser cargado como vector sobre cualquier imagen que se esté trabajando o sobre un archivo vacío. Al aplicar este vector sobre alguna de las imágenes constituyente de la matriz, se podrá generar la máscara necesaria. Para este proceso es necesario ir a: BASIC TOOLS => “Masking” => “Apply Mask”. Sobre la nueva ventana se debe seleccionar la imagen básica y luego ir a “Mask Option” => “Built Mask...”. Luego, en “Options” buscar el vector que se desea aplicar y “Ok”. Luego se deberá guardar la imagen-máscara resultante y “Ok”.

El archivo generado como máscara deberá ser ingresado a MatLab, de la misma manera que se ingresaron las imágenes constituyentes de las matrices 3-D. Una vez que se han generado la máscara en extensión binario, se debe aplicar la función “AplicaMascara.mat”, la cual permitirá la conservación de todos los valores que caen dentro del límite de la cuenca, y aquellos valores fuera de ésta tomarán el valor “NaN”, lo que permitirá un trabajo posterior más simple.

Finalmente, la función “ExtraeCuenca.mat” permitirá la generación de una matriz única por cuenca, constituida por todos los archivos, delimitado por sus extremos N, S, E y W de acuerdo a la ubicación de los píxeles: límite norte (rowb), límite sur (rowl) , límite este (colb), y límite oeste (coll).

ANEXO III
RESUMEN RESULTADOS ENTRENAMIENTO

11.1. RESUMEN RESULTADOS ENTRENAMIENTO

11.1.1. Variación Unidades Capa de Entrada

Tabla 11.1. Resumen resultados, variación nodos de entrada, río Alicahue.

Nodos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
2-0-1	E(x)	1.448	0.736	1.700	0.864	1.519	0.772	1.601	0.814
	s _x	0.166	0.084	0.056	0.029	0.044	0.022	0.195	0.099
4-0-1	E(x)	1.331	0.677	1.375	0.699	1.205	0.612	1.483	0.754
	s _x	0.048	0.024	0.203	0.103	0.059	0.030	0.247	0.125
6-0-1	E(x)	1.112	0.565	0.952	0.484	0.834	0.424	1.096	0.557
	s _x	0.076	0.039	0.041	0.021	0.067	0.034	0.309	0.157
8-0-1	E(x)	0.535	0.272	0.451	0.229	0.692	0.352	0.741	0.377
	s _x	0.029	0.015	0.088	0.045	0.252	0.128	0.079	0.040

Tabla 11.2. Resumen resultados, variación nodos de entrada, río Putaendo.

Nodos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
2-0-1	E(x)	87.092	0.827	98.197	0.932	94.055	0.893	89.572	0.850
	s _x	5.313	0.050	2.808	0.027	8.890	0.084	3.784	0.036
4-0-1	E(x)	71.923	0.683	67.870	0.644	77.597	0.737	57.113	0.542
	s _x	18.064	0.171	11.430	0.109	9.710	0.092	11.042	0.105
6-0-1	E(x)	46.672	0.443	54.877	0.521	63.780	0.605	54.330	0.516
	s _x	9.058	0.086	20.782	0.197	17.939	0.170	15.483	0.147
8-0-1	E(x)	27.817	0.264	47.369	0.450	23.462	0.223	42.917	0.407
	s _x	15.241	0.145	13.519	0.128	3.292	0.031	15.060	0.143

Tabla 11.3. Resumen resultados, variación nodos de entrada, río Juncal.

Nodos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
2-0-1	E(x)	16.295	0.538	18.791	0.621	17.283	0.571	18.692	0.617
	s _x	0.864	0.029	1.816	0.060	1.360	0.045	6.476	0.214
4-0-1	E(x)	14.210	0.469	12.512	0.413	13.480	0.445	12.787	0.422
	s _x	1.876	0.062	1.235	0.041	2.394	0.079	2.722	0.090
6-0-1	E(x)	9.362	0.309	6.402	0.211	8.427	0.278	9.533	0.315
	s _x	1.708	0.056	1.783	0.059	2.482	0.082	2.862	0.095
8-0-1	E(x)	5.087	0.168	8.058	0.266	2.915	0.096	3.754	0.124
	s _x	2.050	0.068	2.198	0.073	0.723	0.024	1.623	0.054

Tabla 11.4. Resumen resultados, variación nodos de entrada, río Pocuero.

Nodos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
2-0-1	E(x)	1.091	0.846	0.883	0.685	0.872	0.676	0.744	0.577
	s _x	0.113	0.087	0.049	0.038	0.040	0.031	0.079	0.062
4-0-1	E(x)	0.722	0.560	0.718	0.557	0.632	0.490	0.605	0.469
	s _x	0.044	0.034	0.059	0.046	0.048	0.037	0.078	0.060
6-0-1	E(x)	0.429	0.333	0.365	0.283	0.476	0.369	0.343	0.266
	s _x	0.038	0.030	0.030	0.023	0.069	0.053	0.011	0.008
8-0-1	E(x)	0.288	0.223	0.195	0.151	0.244	0.189	0.210	0.163
	s _x	0.028	0.022	0.052	0.040	0.137	0.106	0.036	0.028

Tabla 11.5. Resumen resultados, variación nodos de entrada, río Volcán.

Nodos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
2-0-1	E(x)	110.244	0.914	97.907	0.812	89.728	0.744	65.373	0.542
	s _x	12.863	0.107	4.402	0.037	27.616	0.229	28.083	0.233
4-0-1	E(x)	53.471	0.443	44.520	0.369	55.251	0.458	53.961	0.448
	s _x	13.863	0.115	1.427	0.012	5.032	0.042	17.240	0.143
6-0-1	E(x)	31.812	0.264	33.175	0.275	27.406	0.227	29.980	0.249
	s _x	13.386	0.111	4.766	0.040	7.905	0.066	3.682	0.031
8-0-1	E(x)	20.568	0.171	14.116	0.117	22.868	0.190	26.534	0.220
	s _x	9.638	0.080	3.499	0.029	10.488	0.087	19.532	0.162

Tabla 11.6. Resumen resultados, variación nodos de entrada, río Maipo.

Nodos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
2-0-1	E(x)	617.303	0.650	724.183	0.763	861.685	0.907	557.813	0.587
	s _x	206.901	0.218	203.737	0.215	115.622	0.122	27.889	0.029
4-0-1	E(x)	544.890	0.574	404.894	0.426	482.767	0.508	656.569	0.691
	s _x	27.079	0.028	145.926	0.154	80.786	0.085	107.071	0.113
6-0-1	E(x)	314.492	0.331	378.264	0.398	359.951	0.379	380.328	0.401
	s _x	116.071	0.122	87.451	0.092	196.167	0.207	133.811	0.141
8-0-1	E(x)	177.902	0.187	365.867	0.385	264.386	0.278	307.011	0.323
	s _x	44.939	0.047	178.008	0.187	80.394	0.085	65.501	0.069

11.1.2. Variación Unidades Capa Oculta

Tabla 11.7. Resumen resultados, variación nodos de capa oculta, río Alichahue.

Nodos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-0-1	E(x)	1.112	0.565	0.952	0.484	0.834	0.424	1.096	0.557
	s _x	0.076	0.039	0.041	0.021	0.067	0.034	0.309	0.157
6-1-1	E(x)	1.510	0.768	1.449	0.736	1.808	0.919	1.482	0.753
	s _x	0.518	0.263	0.485	0.246	0.128	0.065	0.641	0.326
6-2-1	E(x)	0.749	0.381	1.135	0.577	1.354	0.688	1.479	0.752
	s _x	0.366	0.186	0.646	0.328	0.441	0.224	0.507	0.258
8-0-1	E(x)	0.535	0.272	0.451	0.229	0.692	0.352	0.741	0.377
	s _x	0.029	0.015	0.088	0.045	0.252	0.128	0.079	0.040
8-1-1	E(x)	1.405	0.714	1.343	0.682	0.921	0.468	1.566	0.796
	s _x	0.515	0.262	0.751	0.382	0.799	0.406	0.390	0.198
8-2-1	E(x)	0.828	0.421	0.633	0.322	1.247	0.634	1.117	0.568
	s _x	0.660	0.336	0.465	0.236	0.622	0.316	0.685	0.348

Tabla 11.8. Resumen resultados, variación nodos de capa oculta, río Putaendo.

Nodos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-0-1	E(x)	46.672	0.443	54.877	0.521	63.780	0.605	54.330	0.516
	s _x	9.058	0.086	20.782	0.197	17.939	0.170	15.483	0.147
6-1-1	E(x)	91.896	0.872	102.52	0.973	98.551	0.935	100.60	0.955
	s _x	20.302	0.193	1.696	0.016	9.895	0.094	4.280	0.041
6-2-1	E(x)	93.303	0.886	90.042	0.855	80.736	0.766	86.359	0.820
	s _x	14.383	0.136	14.413	0.137	31.646	0.300	22.657	0.215
8-0-1	E(x)	27.817	0.264	47.369	0.450	23.462	0.223	42.917	0.407
	s _x	15.241	0.145	13.519	0.128	3.292	0.031	15.060	0.143
8-1-1	E(x)	101.799	0.966	104.25	0.990	83.159	0.789	102.52	0.973
	s _x	5.541	0.053	0.981	0.009	32.953	0.313	2.939	0.028
8-2-1	E(x)	92.504	0.878	91.708	0.870	47.772	0.453	86.342	0.820
	s _x	11.015	0.105	12.063	0.115	41.203	0.391	14.396	0.137

Tabla 11.9. Resumen resultados, variación nodos de capa oculta, río Juncal.

Nodos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-0-1	E(x)	9.362	0.309	6.402	0.211	8.427	0.278	9.533	0.315
	s _x	1.708	0.056	1.783	0.059	2.482	0.082	2.862	0.095
6-1-1	E(x)	15.241	0.503	25.574	0.845	18.723	0.618	23.285	0.769
	s _x	6.044	0.200	6.299	0.208	11.461	0.379	10.491	0.346
6-2-1	E(x)	14.445	0.477	15.541	0.513	22.540	0.744	17.791	0.588
	s _x	10.043	0.332	11.393	0.376	7.575	0.250	1.419	0.047
8-0-1	E(x)	5.087	0.168	8.058	0.266	2.915	0.096	3.754	0.124
	s _x	2.050	0.068	2.198	0.073	0.723	0.024	1.623	0.054
8-1-1	E(x)	16.187	0.535	26.429	0.873	20.511	0.677	22.953	0.758
	s _x	10.137	0.335	5.209	0.172	11.871	0.392	5.600	0.185
8-2-1	E(x)	15.729	0.519	18.600	0.614	6.053	0.200	12.503	0.413
	s _x	10.310	0.340	9.087	0.300	6.318	0.209	11.960	0.395

Tabla 11.10. Resumen resultados, variación nodos de capa oculta, río Pocuro.

Nodos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-0-1	E(x)	0.429	0.333	0.365	0.283	0.476	0.369	0.343	0.266
	s _x	0.038	0.030	0.030	0.023	0.069	0.053	0.011	0.008
6-1-1	E(x)	0.874	0.678	0.661	0.512	0.678	0.526	0.596	0.463
	s _x	0.329	0.255	0.217	0.169	0.284	0.221	0.364	0.282
6-2-1	E(x)	0.356	0.276	0.542	0.420	0.296	0.230	0.369	0.287
	s _x	0.074	0.057	0.294	0.228	0.044	0.034	0.137	0.107
8-0-1	E(x)	0.288	0.223	0.195	0.151	0.244	0.189	0.210	0.163
	s _x	0.028	0.022	0.052	0.040	0.137	0.106	0.036	0.028
8-1-1	E(x)	0.808	0.627	0.591	0.458	0.883	0.685	0.705	0.547
	s _x	0.344	0.267	0.269	0.208	0.451	0.350	0.354	0.274
8-2-1	E(x)	0.160	0.124	0.235	0.182	0.368	0.286	0.497	0.386
	s _x	0.065	0.050	0.133	0.103	0.233	0.181	0.508	0.394

Tabla 11.11. Resumen resultados, variación nodos de capa oculta, río Volcán.

Nodos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-0-1	E(x)	31.812	0.264	33.175	0.275	27.406	0.227	29.980	0.249
	s _x	13.386	0.111	4.766	0.040	7.905	0.066	3.682	0.031
6-1-1	E(x)	107.101	0.888	64.240	0.533	106.961	0.887	101.693	0.843
	s _x	18.557	0.154	49.216	0.408	17.824	0.148	25.091	0.208
6-2-1	E(x)	47.648	0.395	95.274	0.790	67.259	0.558	51.165	0.424
	s _x	32.286	0.268	37.952	0.315	40.625	0.337	39.239	0.325
8-0-1	E(x)	20.568	0.171	14.116	0.117	22.868	0.190	26.534	0.220
	s _x	9.638	0.080	3.499	0.029	10.488	0.087	19.532	0.162
8-1-1	E(x)	112.273	0.931	109.182	0.905	79.327	0.658	92.687	0.769
	s _x	8.831	0.073	15.546	0.129	34.537	0.286	40.507	0.336
8-2-1	E(x)	84.246	0.699	97.223	0.806	16.689	0.138	61.350	0.509
	s _x	12.963	0.108	20.974	0.174	18.586	0.154	34.379	0.285

Tabla 11.12. Resumen resultados, variación nodos de capa oculta, río Maipo.

Nodos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-0-1	E(x)	314.492	0.331	378.264	0.398	359.951	0.379	380.328	0.401
	s _x	116.071	0.122	87.451	0.092	196.167	0.207	133.811	0.141
6-1-1	E(x)	885.042	0.932	828.419	0.872	760.855	0.801	866.888	0.913
	s _x	78.696	0.083	114.318	0.120	370.883	0.391	138.670	0.146
6-2-1	E(x)	693.737	0.731	529.322	0.557	613.529	0.646	546.215	0.575
	s _x	187.977	0.198	320.973	0.338	240.354	0.253	267.814	0.282
8-0-1	E(x)	177.902	0.187	365.867	0.385	264.386	0.278	307.011	0.323
	s _x	44.939	0.047	178.008	0.187	80.394	0.085	65.501	0.069
8-1-1	E(x)	889.910	0.937	916.640	0.965	796.110	0.838	919.500	0.968
	s _x	45.687	0.048	62.463	0.066	156.727	0.165	37.253	0.039
8-2-1	E(x)	620.616	0.654	684.074	0.720	563.070	0.593	743.686	0.783
	s _x	128.157	0.135	154.010	0.162	401.022	0.422	211.297	0.222

11.1.3. Retardo Temporal de las Capas

Tabla 11.13. Resumen resultados, retardo temporal sobre configuración: 8-0-1, río Alichahue.

Retardos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
1	E(x)	0.535	0.272	0.451	0.229	0.692	0.352	0.741	0.377
	s _x	0.029	0.015	0.088	0.045	0.252	0.128	0.079	0.040
2	E(x)	2.322	1.180	2.314	1.176	2.296	1.167	2.301	1.170
	s _x	0.043	0.022	0.034	0.017	0.018	0.009	0.019	0.010
4	E(x)	2.309	1.173	2.310	1.174	2.295	1.167	2.320	1.179
	s _x	0.047	0.024	0.024	0.012	0.012	0.006	0.028	0.014
6	E(x)	2.309	1.174	2.274	1.156	2.310	1.174	2.299	1.168
	s _x	0.014	0.007	0.002	0.001	0.035	0.018	0.016	0.008
7	E(x)	2.294	1.166	2.281	1.159	2.714	1.380	2.318	1.178
	s _x	0.016	0.008	0.004	0.002	0.906	0.461	0.006	0.003

Tabla 11.14. Resumen resultados, retardo temporal sobre configuración: 8-0-1, río Putaendo.

Retardos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
1	E(x)	27.817	0.264	47.369	0.450	23.462	0.223	42.917	0.407
	s _x	15.241	0.145	13.519	0.128	3.292	0.031	15.060	0.143
2	E(x)	181.914	1.727	182.789	1.735	189.321	1.797	183.681	1.743
	s _x	0.236	0.002	2.391	0.023	11.746	0.112	4.189	0.040
4	E(x)	181.712	1.725	181.806	1.726	192.644	1.829	184.287	1.749
	s _x	0.000	0.000	0.138	0.001	8.331	0.079	5.758	0.055
6	E(x)	189.517	1.799	181.778	1.725	190.755	1.811	181.932	1.727
	s _x	9.089	0.086	0.091	0.001	12.653	0.120	0.409	0.004
7	E(x)	183.520	1.742	183.850	1.745	185.873	1.764	186.280	1.768
	s _x	2.485	0.024	3.021	0.029	5.701	0.054	10.127	0.096

Tabla 11.15. Resumen resultados, retardo temporal sobre configuración: 8-0-1, río Juncal.

Retardos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
1	E(x)	5.087	0.168	8.058	0.266	2.915	0.096	3.754	0.124
	s _x	2.050	0.068	2.198	0.073	0.723	0.024	1.623	0.054
2	E(x)	58.703	1.939	60.893	2.011	58.446	1.930	58.528	1.933
	s _x	0.437	0.014	3.653	0.121	0.046	0.002	0.228	0.008
4	E(x)	60.365	1.993	58.489	1.932	58.547	1.933	58.975	1.948
	s _x	4.336	0.143	0.088	0.003	0.175	0.006	0.754	0.025
6	E(x)	61.517	2.032	60.427	1.996	60.435	1.996	58.965	1.947
	s _x	6.913	0.228	4.476	0.148	4.492	0.148	1.205	0.040
7	E(x)	59.015	1.949	59.276	1.958	62.140	2.052	58.784	1.941
	s _x	1.107	0.037	1.882	0.062	5.247	0.173	0.800	0.026

Tabla 11.16. Resumen resultados, retardo temporal sobre configuración: 8-0-1, río Pocuro.

Retardos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
1	E(x)	0.288	0.223	0.195	0.151	0.244	0.189	0.210	0.163
	s _x	0.028	0.022	0.052	0.040	0.137	0.106	0.036	0.028
2	E(x)	1.174	0.911	1.099	0.852	1.112	0.862	1.226	0.950
	s _x	0.104	0.081	0.033	0.025	0.099	0.077	0.115	0.089
4	E(x)	1.162	0.901	1.225	0.950	1.167	0.905	1.072	0.832
	s _x	0.120	0.093	0.141	0.109	0.114	0.088	0.025	0.020
6	E(x)	1.420	1.101	1.075	0.834	1.126	0.873	1.115	0.865
	s _x	0.383	0.297	0.008	0.007	0.089	0.069	0.097	0.075
7	E(x)	1.125	0.873	1.095	0.849	1.119	0.868	1.209	0.938
	s _x	0.093	0.072	0.014	0.011	0.097	0.075	0.220	0.170

Tabla 11.17. Resumen resultados, retardo temporal sobre configuración: 8-0-1, río Volcán.

Retardos		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
1	E(x)	16.285	0.135	18.993	0.158	18.495	0.153	26.430	0.219
	s_x	3.050	0.025	9.228	0.077	11.063	0.092	16.032	0.133
2	E(x)	193.764	1.607	190.360	1.579	192.875	1.600	191.180	1.586
	s_x	8.553	0.071	1.498	0.012	7.090	0.059	2.350	0.019
4	E(x)	192.817	1.599	192.196	1.594	197.512	1.638	199.112	1.651
	s_x	6.308	0.052	4.338	0.036	13.608	0.113	12.159	0.101
6	E(x)	194.804	1.616	194.465	1.613	198.059	1.643	191.992	1.592
	s_x	10.292	0.085	10.036	0.083	10.009	0.083	5.074	0.042
7	E(x)	190.948	1.584	189.744	1.574	203.517	1.688	191.447	1.588
	s_x	2.811	0.023	0.120	0.001	17.578	0.146	3.882	0.032

Tabla 11.18. Resumen resultados, retardo temporal sobre configuración: 8-0-1, río Maipo.

Desfase		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
		ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
1	E(x)	177.902	0.187	365.867	0.385	264.386	0.278	307.011	0.323
	s_x	44.939	0.047	178.008	0.187	80.394	0.085	65.501	0.069
2	E(x)	2241.89	2.361	2210.13	2.327	2224.44	2.342	2228.38	2.347
	s_x	22.365	0.024	6.123	0.006	37.921	0.040	38.897	0.041
4	E(x)	2222.15	2.340	2207.72	2.325	2248.70	2.368	2213.42	2.331
	s_x	20.869	0.022	0.727	0.001	39.001	0.041	12.358	0.013
6	E(x)	2242.99	2.362	2216.78	2.334	2222.10	2.340	2241.12	2.360
	s_x	49.697	0.052	19.494	0.021	22.633	0.024	45.836	0.048
7	E(x)	2244.68	2.364	2248.08	2.367	2233.86	2.352	2251.469	2.371
	s_x	44.634	0.047	60.785	0.064	58.872	0.062	45.960	0.048

11.1.4. Inclusión Desfase Temporal entre Series de Tiempo

Tabla 11.19. Variación desfase temporal entre series de tiempo, río Alicahue.

Nodos	Desf. Temp.		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-1	0	E(x)	1.112	0.565	0.952	0.484	0.834	0.424	1.096	0.557
		s_x	0.076	0.039	0.041	0.021	0.067	0.034	0.309	0.157
6-1	10	E(x)	0.470	0.241	0.556	0.285	0.448	0.229	0.559	0.286
		s_x	0.080	0.041	0.072	0.037	0.068	0.035	0.057	0.029
6-1	11	E(x)	0.427	0.218	0.450	0.230	0.454	0.232	0.526	0.269
		s_x	0.055	0.028	0.122	0.062	0.060	0.031	0.060	0.031
6-1	20	E(x)	0.984	0.493	0.890	0.446	0.971	0.487	0.912	0.457
		s_x	0.120	0.060	0.134	0.067	0.083	0.041	0.050	0.025
8-1	0	E(x)	0.535	0.272	0.451	0.229	0.692	0.352	0.741	0.377
		s_x	0.029	0.015	0.088	0.045	0.252	0.128	0.079	0.040
8-1	10	E(x)	0.308	0.158	0.207	0.106	0.319	0.163	0.322	0.165
		s_x	0.162	0.083	0.013	0.007	0.070	0.036	0.109	0.056
8-1	11	E(x)	0.241	0.123	0.216	0.111	0.288	0.147	0.237	0.121
		s_x	0.029	0.015	0.015	0.008	0.154	0.079	0.013	0.007
8-1	20	E(x)	0.586	0.294	0.460	0.231	0.596	0.299	0.595	0.298
		s_x	0.083	0.041	0.058	0.029	0.093	0.047	0.136	0.068

Tabla 11.20. Variación desfase temporal entre series de tiempo, río Putaendo.

Nodos	Desf. Temp.		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-1	0	E(x)	46.672	0.443	54.877	0.521	63.780	0.605	54.330	0.516
		s_x	9.058	0.086	20.782	0.197	17.939	0.170	15.483	0.147
6-1	10	E(x)	32.739	0.314	42.029	0.403	34.568	0.331	25.457	0.244
		s_x	6.965	0.067	7.097	0.068	5.740	0.055	4.698	0.045
6-1	14	E(x)	33.724	0.324	26.156	0.251	28.551	0.274	28.718	0.276
		s_x	7.808	0.075	5.282	0.051	4.970	0.048	10.882	0.105
6-1	20	E(x)	48.230	0.462	36.681	0.351	37.392	0.358	40.312	0.386
		s_x	9.347	0.090	8.182	0.078	8.929	0.086	12.710	0.122
8-1	0	E(x)	27.817	0.264	47.369	0.450	23.462	0.223	42.917	0.407
		s_x	15.241	0.145	13.519	0.128	3.292	0.031	15.060	0.143
8-1	10	E(x)	20.669	0.198	23.022	0.221	19.484	0.187	30.824	0.295
		s_x	6.550	0.063	9.584	0.092	10.006	0.096	11.869	0.114
8-1	14	E(x)	24.956	0.240	25.455	0.245	26.576	0.255	20.088	0.193
		s_x	7.314	0.070	3.853	0.037	10.817	0.104	8.491	0.082
8-1	20	E(x)	21.087	0.202	33.862	0.324	32.543	0.312	26.147	0.250
		s_x	3.860	0.037	11.193	0.107	9.288	0.089	8.024	0.077

Tabla 11.21. Variación desfase temporal entre series de tiempo, río Juncal.

Nodos	Desf. Temp.		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-1	0	E(x)	9.362	0.309	6.402	0.211	8.427	0.278	9.533	0.315
		s_x	1.708	0.056	1.783	0.059	2.482	0.082	2.862	0.095
6-1	10	E(x)	15.868	0.481	10.161	0.308	13.966	0.423	11.961	0.362
		s_x	4.799	0.145	1.295	0.039	2.416	0.073	2.254	0.068
6-1	19	E(x)	7.998	0.247	8.488	0.262	8.589	0.265	7.372	0.227
		s_x	2.379	0.073	1.698	0.052	2.136	0.066	0.839	0.026
6-1	20	E(x)	11.828	0.365	10.604	0.328	8.893	0.275	6.827	0.211
		s_x	2.435	0.075	2.460	0.076	1.980	0.061	1.729	0.053
8-1	0	E(x)	5.087	0.168	8.058	0.266	2.915	0.096	3.754	0.124
		s_x	2.050	0.068	2.198	0.073	0.723	0.024	1.623	0.054
8-1	10	E(x)	7.522	0.228	7.796	0.236	8.613	0.261	8.251	0.250
		s_x	2.467	0.075	0.879	0.027	3.149	0.095	2.616	0.079
8-1	19	E(x)	7.987	0.246	7.044	0.217	6.859	0.212	7.629	0.235
		s_x	2.711	0.084	2.648	0.082	2.377	0.073	2.506	0.077
8-1	20	E(x)	2.639	0.082	6.802	0.210	6.668	0.206	5.120	0.158
		s_x	1.469	0.045	1.709	0.053	2.032	0.063	2.571	0.079

Tabla 11.22. Variación desfase temporal entre series de tiempo, río Pocuro.

Nodos	Desf. Temp.		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-1	0	E(x)	0.429	0.333	0.365	0.283	0.476	0.369	0.343	0.266
		s_x	0.038	0.030	0.030	0.023	0.069	0.053	0.011	0.008
6-1	10	E(x)	0.517	0.404	0.503	0.393	0.500	0.391	0.434	0.339
		s_x	0.020	0.016	0.054	0.042	0.064	0.050	0.091	0.071
6-1	15	E(x)	0.504	0.395	0.529	0.414	0.553	0.433	0.473	0.370
		s_x	0.044	0.035	0.072	0.056	0.045	0.036	0.125	0.098
6-1	20	E(x)	0.614	0.519	0.617	0.522	0.570	0.482	0.637	0.539
		s_x	0.069	0.058	0.020	0.017	0.085	0.072	0.028	0.023
8-1	0	E(x)	0.288	0.223	0.195	0.151	0.244	0.189	0.210	0.163
		s_x	0.028	0.022	0.052	0.040	0.137	0.106	0.036	0.028
8-1	10	E(x)	0.342	0.267	0.439	0.343	0.288	0.225	0.217	0.169
		s_x	0.019	0.015	0.059	0.046	0.032	0.025	0.041	0.032
6-1	15	E(x)	0.343	0.268	0.356	0.278	0.316	0.247	0.381	0.298
		s_x	0.017	0.013	0.040	0.031	0.046	0.036	0.048	0.037
8-1	20	E(x)	0.423	0.358	0.471	0.399	0.432	0.366	0.486	0.411
		s_x	0.115	0.097	0.042	0.035	0.081	0.068	0.105	0.088

Tabla 11.23. Variación desfase temporal entre series de tiempo, río Volcán.

Nodos	Desf. Temp.		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-1	0	E(x)	31.812	0.264	33.175	0.275	27.406	0.227	29.980	0.249
		s_x	13.386	0.111	4.766	0.040	7.905	0.066	3.682	0.031
6-1	10	E(x)	43.917	0.344	48.649	0.382	45.596	0.358	47.217	0.370
		s_x	7.934	0.062	14.528	0.114	7.698	0.060	14.734	0.116
6-1	17	E(x)	42.647	0.337	49.538	0.392	41.175	0.326	38.136	0.302
		s_x	4.314	0.034	8.586	0.068	4.926	0.039	7.246	0.057
6-1	20	E(x)	28.386	0.224	33.866	0.267	27.712	0.219	21.056	0.166
		s_x	5.468	0.043	9.321	0.074	8.499	0.067	5.657	0.045
8-1	0	E(x)	20.568	0.171	14.116	0.117	22.868	0.190	26.534	0.220
		s_x	9.638	0.080	3.499	0.029	10.488	0.087	19.532	0.162
8-1	10	E(x)	34.703	0.272	27.221	0.213	25.904	0.203	25.504	0.200
		s_x	15.015	0.118	3.637	0.029	11.078	0.087	6.400	0.050
8-1	17	E(x)	33.156	0.262	32.976	0.261	32.852	0.260	25.464	0.201
		s_x	8.053	0.064	12.801	0.101	10.817	0.086	4.013	0.032
8-1	20	E(x)	26.089	0.206	34.096	0.269	25.905	0.205	14.578	0.115
		s_x	6.198	0.049	7.974	0.063	8.382	0.066	5.512	0.044

Tabla 11.24. Variación desfase temporal entre series de tiempo, río Maipo.

Nodos	Desf. Temp.		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
6-1	0	E(x)	314.492	0.331	378.264	0.398	359.951	0.379	380.328	0.401
		s _x	116.071	0.122	87.451	0.092	196.167	0.207	133.811	0.141
6-1	10	E(x)	528.284	0.495	661.320	0.620	468.423	0.439	511.022	0.479
		s _x	104.844	0.098	159.340	0.149	67.111	0.063	125.137	0.117
6-1	17	E(x)	387.546	0.369	364.896	0.347	374.701	0.356	445.649	0.424
		s _x	143.326	0.136	98.871	0.094	98.179	0.093	106.012	0.101
6-1	20	E(x)	323.674	0.309	290.758	0.278	341.079	0.326	325.044	0.310
		s _x	69.757	0.067	89.404	0.085	77.789	0.074	69.004	0.066
8-1	0	E(x)	177.902	0.187	365.867	0.385	264.386	0.278	307.011	0.323
		s _x	44.939	0.047	178.008	0.187	80.394	0.085	65.501	0.069
8-1	10	E(x)	426.837	0.400	526.102	0.493	459.265	0.431	537.352	0.504
		s _x	58.710	0.055	38.597	0.036	128.952	0.121	50.418	0.047
8-1	17	E(x)	490.403	0.466	439.755	0.418	451.658	0.430	372.259	0.354
		s _x	72.249	0.069	77.349	0.074	57.231	0.054	76.317	0.073
8-1	20	E(x)	576.219	0.550	335.127	0.320	311.454	0.297	297.074	0.284
		s _x	62.943	0.060	41.635	0.040	77.998	0.074	63.865	0.061

11.1.5. Inclusión de Serie de Porcentaje de Área Cubierta

Tabla 11.25. Resumen resultados, inclusión de serie de porcentaje de nieve, río Alicahue.

Nodos	NDSI		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
8-1	SIN	E(x)	0.535	0.272	0.451	0.229	0.692	0.352	0.741	0.377
		s _x	0.029	0.015	0.088	0.045	0.252	0.128	0.079	0.040
4-1	0.4	E(x)	1.340	0.681	1.381	0.702	1.262	0.641	1.371	0.697
		s _x	0.160	0.081	0.090	0.046	0.109	0.055	0.038	0.019
8-1	0.4	E(x)	0.704	0.358	0.553	0.281	0.476	0.242	0.740	0.376
		s _x	0.059	0.030	0.050	0.026	0.028	0.014	0.062	0.031
4-1	0.7	E(x)	1.318	0.670	1.304	0.663	1.335	0.679	1.320	0.671
		s _x	0.072	0.037	0.118	0.060	0.052	0.027	0.023	0.012
8-1	0.7	E(x)	0.626	0.318	0.528	0.268	0.653	0.332	0.776	0.395
		s _x	0.067	0.034	0.028	0.014	0.132	0.067	0.116	0.059

Tabla 11.26. Resumen resultados, inclusión de serie de porcentaje de nieve, río Putaendo.

Nodos	NDSI		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
8-1	SIN	E(x)	27.817	0.264	47.369	0.450	23.462	0.223	42.917	0.407
		s _x	15.241	0.145	13.519	0.128	3.292	0.031	15.060	0.143
4-1	0.4	E(x)	68.018	0.646	78.816	0.748	73.336	0.696	71.658	0.680
		s _x	5.151	0.049	12.307	0.117	1.937	0.018	9.138	0.087
8-1	0.4	E(x)	36.241	0.344	28.287	0.268	31.610	0.300	28.673	0.272
		s _x	9.508	0.090	12.088	0.115	13.080	0.124	9.581	0.091
4-1	0.7	E(x)	82.807	0.786	78.590	0.746	67.651	0.642	81.592	0.775
		s _x	11.486	0.109	18.202	0.173	13.128	0.125	13.585	0.129
8-1	0.7	E(x)	50.106	0.476	27.607	0.262	21.943	0.208	26.711	0.254
		s _x	21.166	0.201	6.601	0.063	7.128	0.068	6.427	0.061

Tabla 11.27. Resumen resultados, inclusión de serie de porcentaje de nieve, río Juncal.

Nodos	NDSI		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
8-1	SIN	E(x)	5.087	0.168	8.058	0.266	2.915	0.096	3.754	0.124
		s_x	2.050	0.068	2.198	0.073	0.723	0.024	1.623	0.054
4-1	0.4	E(x)	13.006	0.430	12.519	0.413	14.658	0.484	14.661	0.484
		s_x	2.172	0.072	3.341	0.110	1.472	0.049	1.549	0.051
8-1	0.4	E(x)	3.878	0.128	4.100	0.135	4.316	0.143	4.570	0.151
		s_x	0.597	0.020	1.024	0.034	1.347	0.044	1.280	0.042
4-1	0.7	E(x)	13.949	0.461	16.045	0.530	13.279	0.439	13.935	0.460
		s_x	2.197	0.073	2.052	0.068	4.421	0.146	1.441	0.048
8-1	0.7	E(x)	3.479	0.115	7.992	0.264	4.792	0.158	5.260	0.174
		s_x	2.129	0.070	3.785	0.125	1.609	0.053	2.339	0.077

Tabla 11.28. Resumen resultados, inclusión de serie de porcentaje de nieve, estero Pocuro.

Nodos	NDSI		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
8-1	SIN	E(x)	0.288	0.223	0.195	0.151	0.244	0.189	0.210	0.163
		s_x	0.028	0.022	0.052	0.040	0.137	0.106	0.036	0.028
4-1	0.4	E(x)	0.672	0.521	0.669	0.519	0.739	0.573	0.571	0.443
		s_x	0.011	0.009	0.045	0.035	0.028	0.021	0.052	0.041
8-1	0.4	E(x)	0.229	0.178	0.296	0.230	0.254	0.197	0.227	0.176
		s_x	0.027	0.021	0.139	0.108	0.055	0.043	0.058	0.045
4-1	0.7	E(x)	0.710	0.550	0.753	0.584	0.724	0.562	0.632	0.490
		s_x	0.086	0.066	0.044	0.034	0.046	0.036	0.133	0.103
8-1	0.7	E(x)	0.228	0.177	0.196	0.152	0.237	0.184	0.207	0.160
		s_x	0.025	0.019	0.033	0.025	0.062	0.048	0.009	0.007

Tabla 11.29. Resumen resultados, inclusión de serie de porcentaje de nieve, río Volcán.

Nodos	NDSI		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
8-1	SIN	E(x)	20.568	0.171	14.116	0.117	22.868	0.190	26.534	0.220
		s_x	9.638	0.080	3.499	0.029	10.488	0.087	19.532	0.162
4-1	0.4	E(x)	42.687	0.354	58.929	0.489	34.879	0.289	59.509	0.494
		s_x	0.491	0.004	1.304	0.011	3.009	0.025	11.016	0.091
8-1	0.4	E(x)	15.891	0.132	14.142	0.117	17.094	0.142	21.009	0.174
		s_x	2.119	0.018	5.009	0.042	3.373	0.028	3.345	0.028
4-1	0.7	E(x)	54.337	0.451	78.445	0.651	56.029	0.465	53.455	0.443
		s_x	7.380	0.061	10.047	0.083	13.324	0.111	4.968	0.041
8-1	0.7	E(x)	23.099	0.192	14.376	0.119	21.938	0.182	23.461	0.195
		s_x	7.448	0.062	6.254	0.052	6.063	0.050	4.827	0.040

Tabla 11.30. Resumen resultados, inclusión de serie de porcentaje de nieve, río Maipo.

Nodos	NDSI		Píxel-Azar		Píxel-Topografía		Píxel-Cobertura		Píxel-Transecta	
			ECM	ECMN	ECM	ECMN	ECM	ECMN	ECM	ECMN
8-1	SIN	E(x)	177.902	0.187	365.867	0.385	264.386	0.278	307.011	0.323
		s_x	44.939	0.047	178.008	0.187	80.394	0.085	65.501	0.069
4-1	0.4	E(x)	516.941	0.544	322.552	0.340	495.701	0.522	671.259	0.707
		s_x	241.472	0.254	31.341	0.033	278.692	0.293	228.834	0.241
8-1	0.4	E(x)	243.720	0.257	206.319	0.217	220.054	0.232	215.679	0.227
		s_x	87.688	0.092	82.188	0.087	64.709	0.068	78.325	0.082
4-1	0.7	E(x)	484.540	0.510	531.724	0.560	474.199	0.499	526.556	0.555
		s_x	44.338	0.047	258.156	0.272	56.881	0.060	244.036	0.257
8-1	0.7	E(x)	354.724	0.374	438.936	0.462	234.536	0.247	225.316	0.237
		s_x	144.201	0.152	138.443	0.146	88.836	0.094	75.153	0.079