

Trabajo Fin de Máster

MODELO DE PREDICCIÓN DE APORTACIONES MENSUALES UTILIZANDO REDES NEURONALES ARTIFICIALES. APLICACIÓN A LA CUENCA DEL RÍO AMAMBAÍ (BRASIL)

Intensificación: RECURSOS HÍDRICOS

Autor:

GIOVANNI GOMES VILLA TRINIDAD

Director:

DR. RAFAEL GARCÍA-BARTUAL

Noviembre, 2016



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA

máster en ingeniería
hidráulica y medio ambiente
mihma

Trabajo Fin de Máster

MODELO DE PREDICCIÓN DE APORTACIONES MENSUALES UTILIZANDO REDES NEURONALES ARTIFICIALES. APLICACIÓN A LA CUENCA DEL RÍO AMAMBAÍ (BRASIL)

Intensificación: Recursos Hídricos.

Autor:

Giovanni Gomes Villa Trinidad

Director:

Dr. Rafael García-Bartual

Noviembre, 2016

Agradecimientos

A toda mi familia, por su apoyo desde siempre para incentivar me a seguir con mi formación profesional.

Un especial agradecimiento y gratitud a mi asesor, el Dr. Rafael García-Bartual, por haberme guiado siempre, por su tiempo y dedicación, inclusive a la distancia, para la finalización de este TFM. Sin él, no lo hubiera logrado.

Al Ing. Calixto Saguier y a los miembros del Consejo de Becas de Posgrado de la Itaipu, por la confianza depositada en mi persona, para ser beneficiado con la Beca de Posgrado de la Itaipu.

Al Ing. José M. Rivarola, por haberme facilitado la posibilidad de realizar la pasantía en la División de Estudios Hidrológicos y Energéticos de la Itaipu.

A Lenin Henriquez y Anahí Miner, por todo el apoyo durante el Máster, por las horas de estudio, consejos, compañía y orientación durante nuestra estancia en Valencia, y por la invaluable colaboración para estructurar este TFM.

A Mario Arzamendia, por las revisiones y sugerencias hechas a este TFM.

A Carlos Echeverría y Mari Carmen Guillem, por las traducciones.

Resumen

La modelación hidrológica, con fines de previsión de caudales tiene hoy varias alternativas con relación a la modelación clásica. Estos métodos alternativos de predicciones, van ganando espacio y conocimiento en hidrología. Las limitaciones encontradas en la implementación de un modelo hidrológico conceptual clásico, ya sea distribuido o agregado, en cuanto a los datos necesarios para su aplicación, hace que en algunos casos y dependiendo del objetivo, sea factible optar por una metodología basada exclusivamente en datos, como son las Redes Neuronales Artificiales (RNA).

Las RNA son un sistema computacional estructurado, basado en el funcionamiento del cerebro humano, en el que se procesan datos de entradas a lo largo de la red, para obtener un dato de salida, y pueden ser una interesante herramienta de predicción, que no solo tienen las ventajas mencionadas más arriba, con relación a un modelo clásico de previsión hidrológica, sino que, tienen la gran ventaja de ser muy adaptables a las necesidades del *modelador*, que define desde el diseño inicial hasta el algoritmo de calibración. Por más que sea considerado como un modelo de *caja negra*, su versatilidad es una de las principales ventajas para este tipo de modelo.

La predicción temprana de caudales, es de fundamental importancia para cualquier hidroeléctrica, especialmente para la planificación y operación y más aún, para una tan importante como la Itaipu (14.000 MW capacidad instalada), por su generación y aporte a los sistemas eléctricos tanto para el Paraguay (75%) y el Brasil (15%).

Basado en una necesidad real de la División de Estudios Hidrológicos y Energéticos de la Itaipu, de mejorar sus predicciones hidrológicas mensuales, se ha desarrollado un modelo de previsión de caudales mensuales usando RNA, de uno de los cinco ríos de la cuenca incremental, el río Amambaí, localizado en el estado de Mato Grosso do Sul, Brasil. Han sido diseñadas y evaluadas seis RNA variando datos de entradas y neuronas ocultas, y se han obtenido resultados con coeficientes de correlación de 83% a 90% en la fase de verificación con otros eventos.

Abstract

Hydrological modeling, for flow prediction purposes, has today several alternatives regarding to traditional modeling. These alternative prediction methods are growing in terms of usage and knowledge in hydrology. The limitations found in the implementation of a classical conceptual hydrological model, either distributed or lumped, in terms of the data required for its application makes that, in some cases and depending on the target, is feasible to choose for an alternative model approach based exclusively on data, such as Artificial Neural Networks (ANN).

The ANN are a structured computer system based on the behavior of the human brain, in which *inputs* data are processed along the network to obtain an output data, and could be an interesting prediction tool, not only because the advantages above-mentioned, concerning to a classical hydrological prediction model, but also because they have a great advantage of being very adaptable for the *modeler* requirements, who defines from the initial design to the training algorithm. Despite being considered as a *black-box* model, its versatility is one of the main advantages of this type of model.

Early flow prediction, it is extremely important for any hydroelectric plant, especially for the planning and operation and even more for one like Itaipu (14.000 MW installed capacity) because of its generation and contribution to the electrical systems for both countries, Paraguay (75%) and Brazil (15%).

Based on a real need of the Division of Hydrological and Energy Studies of Itaipu to improve its monthly hydrological predictions, a monthly flow prediction model using ANN have been developed for one of the five rivers in the incremental basin, the Amambaí River, located in the state of Mato Grosso do Sul, Brazil. Six ANN have been designed and evaluated varying the inputs data and hidden neurons, obtaining 83% to 90% of correlation coefficient in the verification phase with other events.

Resum

La modelació hidrològica amb finalitats de previsió de cabals, té hui dia diverses alternatives respecte a la modelació clàssica. Aquests mètodes alternatius de prediccions, van guanyant espai i coneixement en la hidrologia. Les limitacions trobades en la implementació d'un model hidrològic conceptual clàssic, siga distribuït o agregat, pel que fa a les dades necessàries per a la seua aplicació, fan que en alguns casos, i depenent de l'objectiu, siga factible escollir una metodologia basant-se exclusivament en les dades, com són les Xarxes Neuronals Artificials (XNA).

Les XNA són un sistema computacional estructurat, basat en el funcionament del cervell humà, que processa dades d'entrades, al llarg de la xarxa, per a obtenir una dada d'eixida. Poden ser una interessant ferramenta de predicció, que no tan sol té els avantatges esmentats més amunt, en relació amb un model clàssic de previsió hidrològica, sinó que, tenen el gran avantatge de ser molt adaptables a les necessitats de *l'usuari del model*, que definix des del disseny inicial fins a l'algoritme de calibratge. Per més que siga considerat com un model de *caixa negra*, la seua versatilitat és uns dels principals avantatges per a aquest tipus de model.

La predicció primerenca de cabals, és de fonamental importància per a qualsevol hidroelèctrica, especialment per a la planificació i l'operació, i més encara, per a una de tan important com l'Itaipu (14.000 MW capacitat instal·lada), per la seua generació i aportació als sistemes elèctrics del Paraguai (75%) i del Brasil (15%).

Basat en una necessitat real de la Divisió d'Estudis Hidrològics i Energètics de l'Itaipu, per tal de millorar les seues prediccions hidrològiques mensuals, s'ha desenvolupat un model de previsió de cabals mensuals, utilitzant XNA, d'un dels cinc rius de la conca incremental, el riu Amambaí, que es troba a l'estat del Mato Grosso do Sul, Brasil. S'han dissenyat i avaluat sis diverses XNA variant-ne dades d'entrades i de neurones ocultes i s'han obtingut resultats amb coeficients de correlació de 83% a 90% en la fase de verificació amb altres esdeveniments.

Contenido

1. Introducción.....	6
1.1. Motivo de estudio	7
1.2. Objetivos	8
1.3. Justificativa	8
1.4. Contribuciones	9
2. Itaipu Binacional.....	10
2.1. Antecedentes y Características técnicas	10
2.2. Descripción del Sistema Hídrico de Itaipu	20
2.3. La División de Estudios Hidrológicos (OPSH)	26
3.Redes Neuronales Artificiales (RNA).....	28
3.1. Inspiración biológica de las RNA.....	28
3.2. Descripción de las RNA.....	32
3.3. Entrenamiento de una RNA.....	36
3.4. Modelación Hidrológica con RNA.....	38
4.RNA para predicción de caudales: Antecedentes	42
5.Metodología	49
5.1. Antecedentes	49
5.2. Metodología propuesta.....	49
6.Estudio de caso	58
6.1. Río Amambáí	58
6.1.1. Descripción de la cuenca	58
6.2. Estación Florida.....	59
6.3. Análisis de datos	60
6.3.1. Correlaciones entre variables.....	60
6.4. Selección de Inputs.....	64
7.Resultados y discusiones.....	67
8.Conclusiones y Recomendaciones	86
9.Referencias.....	88
10.Anexo.....	91

Lista de Figuras

Figura 1 Ubicación geográfica de la Central Hidroeléctrica de Itaipu.	10
Figura 2 Vista de la isla de Itaipu. Año 1974.....	11
Figura 3 Construcción del canal de desvío del río Paraná en Itaipu	12
Figura 4 Esquema general del proyecto.	13
Figura 5 Vista frontal del vertedero.....	14
Figura 6 Detalle de las compuertas del vertedero.....	14
Figura 7 Sección transversal típica. Presa de tierra.....	15
Figura 8 Sección transversal típica. Presa de enrocado.	15
Figura 9 Sección transversal típica. Presa de contrafuertes.	16
Figura 10 Sección transversal típica. Presa de gravedad aliviada.	17
Figura 11 Sección transversal típica. Presa de gravedad maciza.	17
Figura 12 Vista aérea de la casa de máquinas.	18
Figura 13 Casa de Máquinas. Ubicación de los equipamientos principales.	19
Figura 14 Cuenca del río Paraná con los ríos, Grande y Paranaíba.	20
Figura 15 Centrales en la cuenca del Río Paraná aguas arriba de la Itaipu.....	21
Figura 16 Cuenca incremental de aguas arriba de la Central de Itaipu.....	22
Figura 17 Mapa de altimetrías de la cuenca incremental de la Itaipu.....	23
Figura 18 Esquematación del Sistema Hídrico de la Itaipu. Aguas arriba.	24
Figura 19 Ubicación cuenca de aguas abajo de la CH Itaipu.....	25
Figura 20 Organigrama de la Dirección Técnica.....	26
Figura 21 Componentes de una neurona biológica. Fuente: Wikipedia.	29
Figura 22 Neurona Artificial. Fuente: Adaptado de Haykin 1999.....	33
Figura 23 Esquema del momento de la previsión de caudales.	50
Figura 24 Tipo y arquitectura de red adoptada.	53
Figura 25 Ventana de carga de datos y de creación de la RNA en el MATLAB.....	55
Figura 26 Ventana de vista de la RNA diseñada	55
Figura 27 Ventana de entrenamiento de la RNA	55

Figura 28 Ventanas de visualización de resultados de simulaciones.....	56
Figura 29 Ubicación geográfica de la cuenca del río Amambaí en la cuenca incremental de Itaipu.	58
Figura 30 Estación hidrometeorológica Florida y lance de reglas limnimétricas.	59
Figura 31 Correlaciones entre caudal a predecir y caudales anteriores.....	60
Figura 32 Correlaciones entre caudal a predecir y las precipitaciones.	61
Figura 33 Correlaciones entre caudal a predecir y las temperaturas de la sup. del mar.	62
Figura 34 Correlaciones entre caudal a predecir y la presión a nivel del mar.	62
Figura 35 Correlaciones entre caudal a predecir y el índice de oscilación del sur.	63
Figura 36 Índices de ajustes y errores. RN2.....	67
Figura 37 Caudales Observados vs. Simulados. RN1	68
Figura 38 Hidrogramas Observados y Simulados. Serie completa. RN1	69
Figura 39 Hidrogramas Observados vs. Simulados. Serie del TEST. RN1	69
Figura 40 Índices de ajustes y errores. RN2.....	70
Figura 41 Caudales Observados vs. Simulados. RN2	71
Figura 42 Hidrogramas Observados y Simulados. Serie completa. RN2	71
Figura 43 Hidrogramas Observados vs. Simulados. Serie del TEST. RN2.....	72
Figura 44 Índices de ajustes y errores. RN3.....	72
Figura 45 Caudales Observados vs. Simulados. RN3	73
Figura 46 Hidrogramas Observados y Simulados. Serie completa. RN3	73
Figura 47 Hidrogramas Observados vs. Simulados. Serie del TEST. RN3	74
Figura 48 Índices de ajustes y errores. RN4.....	74
Figura 49 Caudales Observados vs. Simulados. RN4	75
Figura 50 Hidrogramas Observados y Simulados. Serie completa. RN4	76
Figura 51 Hidrogramas Observados vs. Simulados. Serie del TEST. RN4	76
Figura 52 Índices de ajustes y errores. RN5.....	77
Figura 53 Caudales Observados vs. Simulados. RN5	78
Figura 54 Hidrogramas Observados y Simulados. Serie completa. RN5	78

Figura 55 Hidrogramas Observados vs. Simulados. Serie del TEST. RN5	79
Figura 56 Índices de ajustes y errores. RN6.....	79
Figura 57 Caudales Observados vs. Simulados. RN6	80
Figura 58 Hidrogramas Observados y Simulados. Serie completa. RN6	81
Figura 59 Hidrogramas Observados vs. Simulados. Serie del TEST. RN6	81
Figura 60 Índices de ajustes y de errores de las 6 mejores RNA. Series del TEST	82
Figura 61 Hidrogramas simulados de las seis mejores RNA obtenidas. Series del TEST. ...	84

Lista de Tablas

Tabla 1 Caudales de Centrales Hidroeléctricas y ríos afluentes al río Paraná. Aguas arriba de la CH Itaipu.	24
Tabla 2 Componentes fijos y variables de las RNA a ser entrenadas.....	54
Tabla 3 Resumen de las correlaciones entre caudal a predecir y las diferentes variables....	64
Tabla 4 Resumen de las 6 RNA con sus respectivos inputs a ser diseñadas.	65
Tabla 5 Comparación de resultados con modelo trivial Naive.....	84

1. Introducción

El gran potencial hidroeléctrico del río Paraná en el tramo comprendido entre los Saltos del Guairá y el lugar conocido como Itaipu, hizo factible técnica y económicamente la posibilidad de la construcción de la presa del mismo nombre, Itaipu, entre los gobiernos de Paraguay y Brasil.

Se han realizado diversos estudios hidrológicos, que datan inclusive desde inicios del siglo pasado, intensificándose los mismos, a finales de la década del 60 e inicio de la del 70, ya para los primeros estudios de factibilidad del emprendimiento.

En aquel entonces, se realizan las primeras mediciones de caudales del río Paraná en la zona de Guairá, Brasil, se instalan los primeros limnógrafos, se traza la curva de descarga para de esa forma poder evaluar los caudales en forma más detallada.

Así que, desde antes de la construcción de la Itaipu Binacional, se han estudiado con mucho detalle y cuidado al río Paraná, y en especial atención a los caudales que el mismo transporta a lo largo de su trayectoria, ya que este es el principal *protagonista* en un emprendimiento hidroeléctrico.

El proceso de generación de energía hidroeléctrica, de cualquier Central, se encuentra sujeto a unos estándares de calidad, en cada uno de los sub-procesos, pasando por las diversas transformaciones de energía que se presentan; de la energía potencial en cinética, luego a mecánica y finalmente en energía eléctrica.

El primer sub-proceso en la línea de la programación energética de una Central Hidroeléctrica, es el cálculo de la disponibilidad del recurso hídrico, el cual tiene en general dos componentes principales, el primero, el aporte de caudal regulado por los sistemas de Centrales que se encuentran aguas arriba, y el segundo, es el aporte *extra* de los ríos laterales o afluentes, cuyos caudales llegan a ser importantes en momento de crecidas generadas por precipitaciones en sus cuencas.

Para satisfacer las demandas de energía, se deben conocer a cabalidad y con cierto grado de precisión, cuál va a ser la disponibilidad de energía para los próximos días, semanas y meses, principalmente para Centrales de gran porte como

lo es Itaipu, con una potencia instalada de 14.000 MW, y una generación promedio diaria anual de 10.500 MW (aprox.). Por esta razón es que la previsión de caudales es de suma importancia para garantizar la atención a las demandas de ambos países propietarios.

La previsión de caudales a escala mensual, con un buen grado de confiabilidad, proporciona a una Central una cierta confianza a la hora de atender los compromisos asumidos de provisión de energía, y en el caso de la Itaipu Binacional, a nivel mensual es una cantidad de energía más que importante, por lo que, de este modo, queda bien establecida la importancia de las previsiones de caudales con un alto grado de confianza.

En la actualidad, la OPSH no cuenta con una metodología científica para realizar las previsiones de caudales mensuales de su cuenca incremental (o cuenca de interés), de ahí que este Trabajo Fin de Máster (TFM) pretende ser el inicio de otras investigaciones, ya sean con la metodología empleada en este TFM de Máster, las Redes Neuronales Artificiales (RNA) o con la metodología que sea seleccionada para tal efecto.

1.1. Motivo de estudio

La motivación para realizar este estudio, es cumplir con el Trabajo Fin de Máster (TFM), requisito último, para la obtención del título de Máster en Ingeniería Hidráulica y Medio Ambiente (MIHMA) de la Universidad Politécnica de Valencia (UPV)-España.

Como becario, seleccionado por la Central Hidroeléctrica de Itaipu (CHI), para cursar el MIHMA en la UPV, periodo lectivo 2009-2010, al regreso a Paraguay, he tenido la posibilidad de acceder como becario en el año 2011 a la División de Estudios Hidrológicos y Energéticos (OPSH) de la CHI, para realizar el TFM sobre un tema de interés de la OPSH, resultando el mismo, en elaborar un modelo de predicciones de caudales de ríos a nivel mensual.

Este interés de Itaipu, se centra principalmente en disponer de una metodología, con más sustento técnico-científico, en comparación con el que actualmente se utiliza, el cual es una estimación estadística, teniendo en cuenta los

promedios históricos mensuales y la situación climática basada en la situación antecedente y en las tendencias climáticas que hacen referencia, las diversas instituciones meteorológicas del Brasil y Paraguay.

1.2. Objetivos

El principal objetivo de este TFM, es desarrollar un modelo de predicciones de caudales, basado en las técnicas de las RNA, como herramienta de apoyo para las predicciones del caudal promedio del mes siguiente del río analizado.

Otros objetivos son:

- Verificar el desempeño de la red, con la utilización de predicciones de precipitaciones del mes siguiente, con relación a una red que no la usa.
- Comprobar el desempeño de la red, con la utilización de un índice que proporciona información sobre el fenómeno de *El Niño*.

1.3. Justificativa

El uso de las RNA en modelación hidrológica es una alternativa totalmente válida, a la modelación tradicional que se basa en la física de los fenómenos presentes en la cuenca, y que, en la muchos casos es de difícil representación por lo que implica la variabilidad espacial en la cuenca, y no solo de estos fenómenos, sino también en lo que respecta a las características físicas de la cuenca como el tipo de suelo, del uso del suelo, topografía, etc.

La aplicación de RNA, a la predicción de caudales, implica en la mayoría de los casos, el uso de datos de caudales, provenientes de registros de estaciones fluviométricas y el de datos de precipitación, que puede ser, precipitación promedio en la cuenca o el dato directo del registro del pluviómetro, sin tener en consideración otra característica física de la cuenca o el conocimiento de algún fenómeno a ser representado a través de una ecuación.

Algunos autores como Hsu et al. (1995), Ochoa (2002); Solomatine (2008), Nilsson et al. (2005), Dolling y Varas (2001); Dawson y Wilby (2001), Poveda et al.

(2002); Garbrecht (2006); Kişi (2007); Prada and Obregón (2009); Pujol (2009), que han aplicado las RNA en modelación hidrológica, con buenos resultados y han recomendado ampliamente su utilización en predicción de caudales.

1.4. Contribuciones.

En cuanto a lo que se pretende contribuir con este TFM a la OPSH, por sobre todo, es colaborar con una metodología, de las RNA, para realizar las predicciones de caudales promedios mensuales en los ríos de la cuenca incremental o de interés, iniciando el estudio en uno de los cinco ríos de la cuenca incremental.

También, promover la implementación de las RNA a los otros ríos de la cuenca incremental de la CHI, para que de esa forma se tenga una estimación más precisa del valor de caudal promedio mensual a ser presentado a las demás instancias dentro de la empresa y que sirva de esa forma como subsidio a la programación energética de largo plazo.

Por último, poner a disposición, un material didáctico, paso a paso, sobre cómo implementar un modelo de predicción de caudales, en forma clara y sencilla, y que sirva a otros estudiantes y profesionales de lengua castellana, principalmente, como material de referencia inicial en el área de la modelación hidrológica.

2. Itaipu Binacional

2.1. Antecedentes y Características técnicas

La Central Hidroeléctrica ITAIPU BINACIONAL, es en la actualidad la segunda hidroeléctrica en potencia instalada, y representa el esfuerzo y compromiso de dos países vecinos, Paraguay y Brasil, para desarrollar sus recursos energéticos a favor de sus beneficios comunes.

Está localizado en el río Paraná, en la frontera entre los dos países, a 14 Km. aguas arriba del Puente Internacional de la Amistad, que une las ciudades de Ciudad del Este de Paraguay y Foz do Iguaçu de Brasil. Figura 1.



Figura 1 Ubicación geográfica de la Central Hidroeléctrica de Itaipu.

El nombre de ITAIPU, originalmente es de una pequeña isla de piedras situada donde fue construida la presa misma, proviene del Guaraní, lengua nativa de los indios Guaraníes, y significa *pedra que canta*, por el sonido que se escuchaba cuando las aguas del río Paraná golpeaban las piedras de dicha isla, figura 2.



Figura 2 Vista de la isla de Itaipu. Año 1974.

En el lugar conocido como los Saltos del Guairá, distante unos 190 Km. aguas arriba del lugar actual de Itaipu, el río Paraná, antes de la construcción de la misma, se encontraba una caída (o salto) de alrededor de 100 metros, seguido por un tramo turbulento de 60 Km. En los restantes 130 Km. el tramo del río pasa a tener una forma *encajonada* y en el cual pasa a ganar otros 20 metros de caída, completando de esta forma unos 120 metros de caída total, en el tramo bi-nacional del río y con un posible potencial hidroeléctrico a ser aprovechado.

Los primeros estudios del potencial hidroeléctrico de los Saltos del Guairá, se remontan al año 1955, hechos por el gobierno brasileño, contratando a una empresa canadiense, LIGHT. Ya en la década de los 60, ante una creciente demanda por energía eléctrica en el Brasil, se realizan los primeros estudios de factibilidad de un Proyecto Hidroeléctrico en la zona mencionada. En el año 1966, los países firman un Acta conocido como el Acta de Iguazú, en el cual se establece la intención en común acuerdo entre ambos, de llevar adelante estudios conjuntos para los aprovechamientos de estos recursos hidráulicos. En el año 1967, se crea una Comisión Técnica Mixta Paraguayo-Brasileña para llevar adelante los estudios iniciales, y se firma un acuerdo de cooperación con la Administración Nacional de Electricidad (ANDE) de Paraguay y la Centrales Eléctricas Brasileñas S.A. (ELETROBRAS) de Brasil.

A inicios de los 70, se decide que la ejecución de los diversos estudios sean llevados a cabo por un consorcio internacional, la IECO-ELC, conformado por las

empresas *International Engineering Company Inc.* de San Francisco, U.S.A. y la *Electroconsult Spa* de Milán, Italia. Estos estudios incluyeron: reconocimiento de campo, análisis hidrológicos, investigaciones geotécnicas, alternativas de proyectos en cuanto a ubicación y tipo de estructuras a ser utilizada.

A modo de culminación de las negociaciones ya iniciadas en los 60, en Abril de 1973 se firma el Tratado de ITAIPU entre los países de Paraguay y Brasil. Siendo en el año 1974 el establecimiento oficial de la Entidad Itaipu Binacional con la creación de un Consejo de Administración y un Directorio Ejecutivo para su gerenciamiento bi-nacional entre ambos países.

Para el diseño final de Ingeniería, se forma un consorcio de empresas consultoras paraguayas y empresas brasileñas.

En Mayo de 1975, se da el inicio efectivo de las obras, y se decide mantener al consorcio *IECO-ELC* como coordinador general de las obras de ingeniería. Se conforman dos consorcios de empresas constructoras pre-calificadas anteriormente, *CONEMPA* de Paraguay y *UNICON* del Brasil.

Una de las etapas más importantes de la obra, fue sin duda, la construcción del canal de desvío del río Paraná, para que de esa forma se pueda trabajar en la construcción de la presa principal y casa de máquinas. El canal de desvío se construyó con una capacidad de descarga de 35.000 m³/seg. En la figura 3 se muestran las etapas de la construcción del canal.

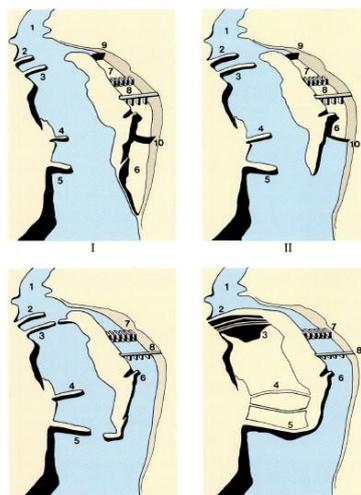


Figura 3 Construcción del canal de desvío del río Paraná en Itaipu

La estructura de desvío cuenta con 12 compuertas de 6,70 metros de ancho y 22 metros de alto, y se asienta en la cota 83,00 msnm.

Pasando ya a la etapa final, a continuación, en la figura 4 se presenta la planta general del proyecto terminado, con la disposición de todas las instalaciones, estructuras y presas componentes.

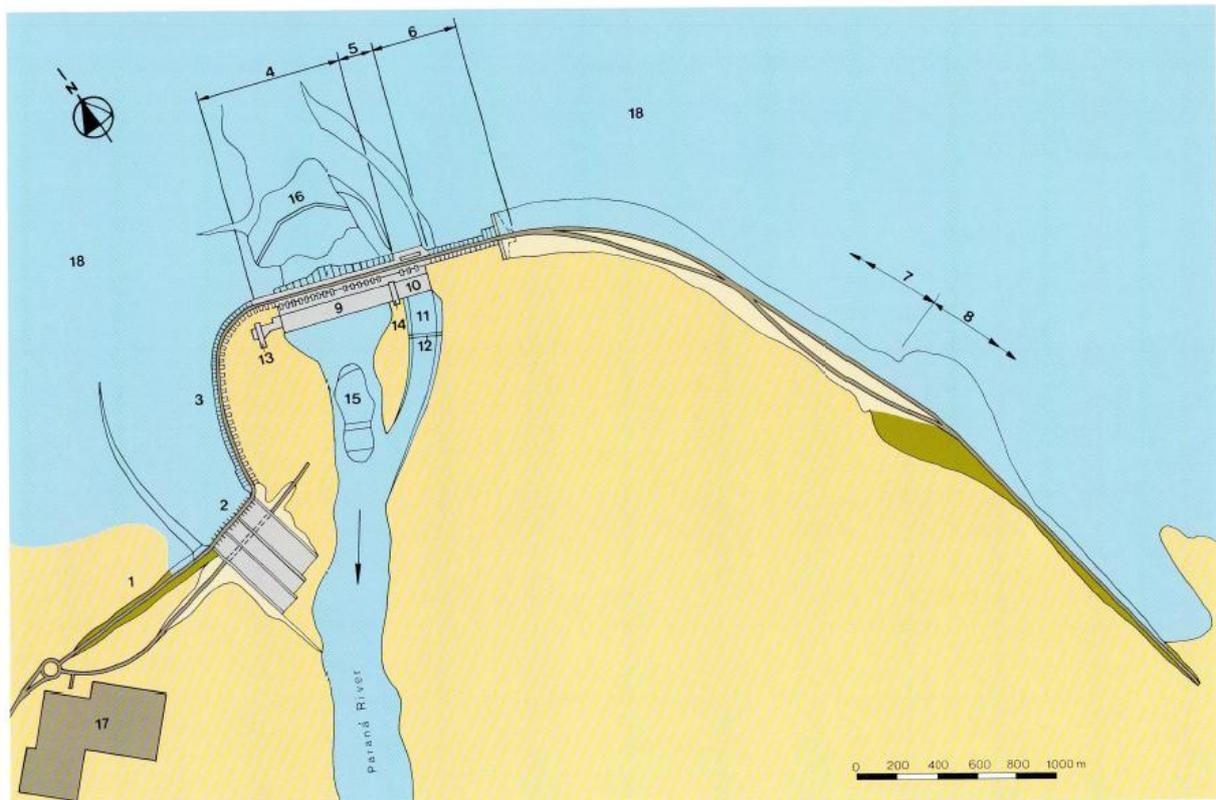


Figura 4 Esquema general del proyecto.

- | | |
|--|--|
| 1 Presa de tierra Margen Derecha (MD) | 10 Casa de máquinas en canal de desvío |
| 2 Vertedero | 11 Canal de desvío |
| 3 Presa de contrafuertes | 12 Puente de servicio |
| 4 Presa principal de gravedad aliviada | 13 Área de montaje (MD) |
| 5 Estructura de desvío | 14 Área de montaje (MI) |
| 6 Presa de contrafuertes Margen Izquierda (MI) | 15 Ataguías de aguas abajo |
| 7 Presa de enrocado | 16 Ataguías de aguas arriba |
| 8 Presa de tierra (MI) | |
| 9 Casa de máquinas en presa principal | |

Otra estructura hidráulica importante, es el vertedero, figura 5, construido en la margen derecha del río Paraná, es del tipo canal inclinado con una estructura de control en forma de ojiva, dividida en tres canaletas, cada una de ellas con su propio salto de esquí, siendo el largo de la canaleta izquierda de 430 m., la central 450 m. y la derecha de 470 m. Tiene una capacidad de descarga de 62.200 m³/seg.



Figura 5 Vista frontal del vertedero

Posee 14 compuertas de 20,00 m. de ancho y 21,34 m. de altura, son del tipo radial, figura 6.

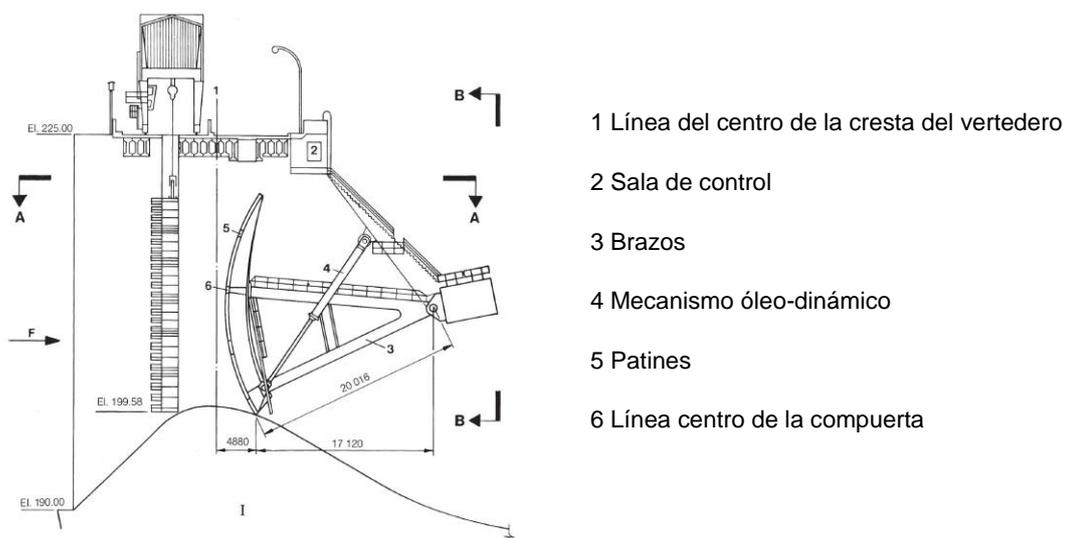


Figura 6 Detalle de las compuertas del vertedero

En cuanto a las presas en sí, se tienen en total 4 tipos de presas, las cuales serán descritas brevemente a continuación.

Presas de tierra, en la margen derecha ubicación 1 y en la margen izquierda ubicación 8 de la figura 4 mostrada más arriba. En total, sumando las presas de tierra de ambas márgenes se tiene en total más de 3000 metros lineales de presa de tierra. En la figura 7, se muestra la sección transversal típica de la presa de tierra.

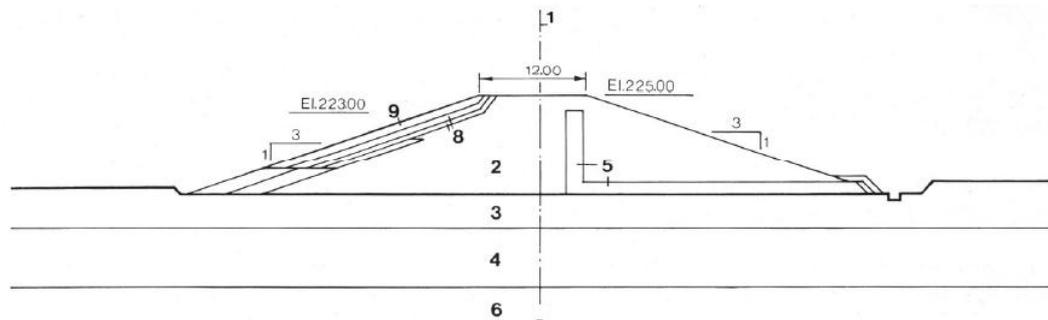


Figura 7 Sección transversal típica. Presa de tierra.

- | | |
|---------------------|------------------------------|
| 1 Eje de la presa | 5 Filtro de arena artificial |
| 2 Núcleo de arcilla | 6 Basalto denso |
| 3 Arcilla plástica | 8 Transición graduada |
| 4 Roca | 9 Rip-Rap |

La presa de enrocado se sitúa en la margen izquierda, según la figura 4. En total posee una longitud de alrededor de 1900 metros lineales. En la figura 8 se muestra una sección transversal típica de la presa de enrocado.

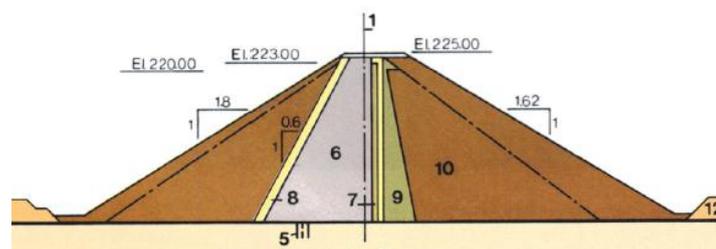


Figura 8 Sección transversal típica. Presa de enrocado.

- | | |
|---------------------------------|---------------------|
| 1 Eje de la presa | 8 Transición fina |
| 5 Cortina de inyección | 9 Transición gruesa |
| 6 Núcleo de arcilla impermeable | 10 Enrocado |
| 7 Filtro de arena artificial | 12 Terreno natural |

Luego, en cuanto a las presas de hormigón, se tienen tres tipos: la presa de contrafuertes, la presa principal que es de gravedad aliviada, y la presa del canal de desvío que es de gravedad maciza o sólida.

Las presas de contrafuertes, se encuentran, en la margen derecha en la transición entre el vertedero y la presa principal, y en la margen izquierda en la transición entre la presa de gravedad del canal de desvío y la presa de enrocado. Tiene en total una longitud de 1400 metros y posee 9183 bloques. En la figura 9 se presenta una sección transversal típica de la presa de contrafuertes.

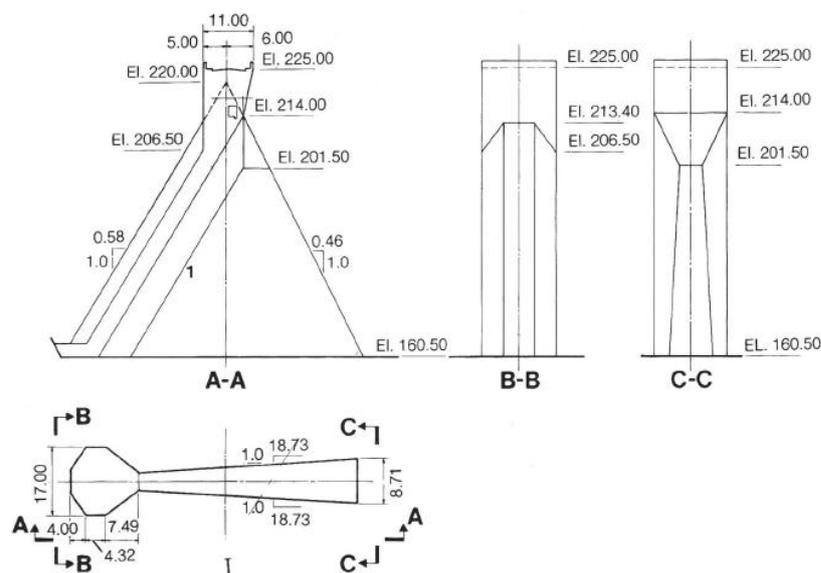


Figura 9 Sección transversal típica. Presa de contrafuertes.

La presa principal es de gravedad aliviada (hueca), tiene una longitud total de 612 metros y está formada por 36 bloques monolíticos, y en que cada uno de ellos, consiste en una cabeza apoyada en *dos piernas* de contrafuerte y cerrada por otra cabeza en la parte de aguas abajo.

En la parte superior de la presa, se encuentran las tomas de agua y los respectivos conductos forzados de 10,50 metros de diámetro. En la figura 10, se muestra una sección transversal típica de la presa de gravedad aliviada.

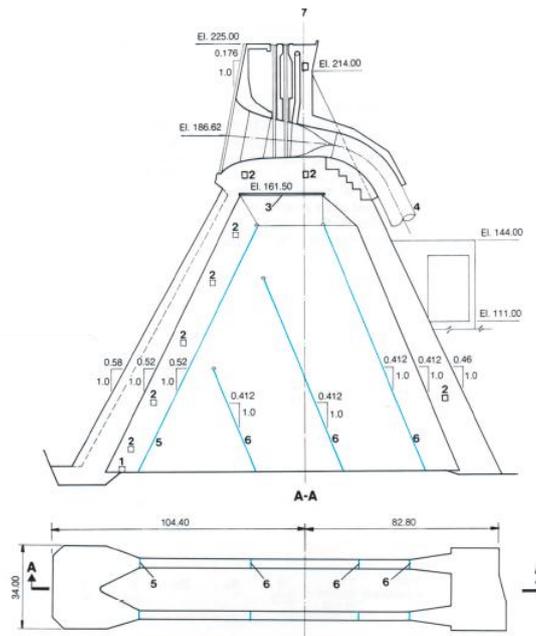
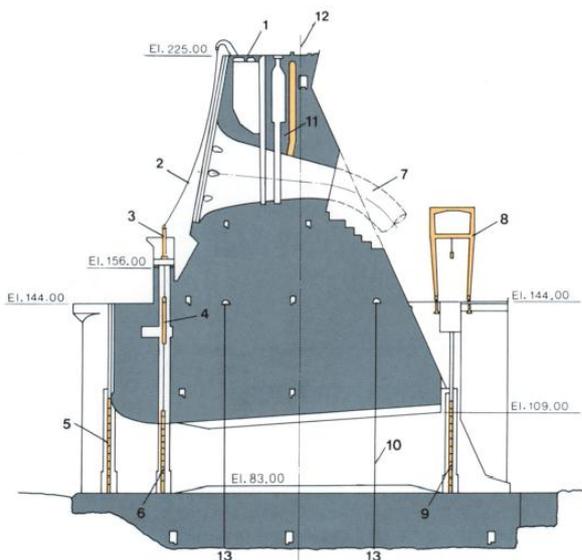


Figura 10 Sección transversal típica. Presa de gravedad aliviada.

- | | |
|---------------------------------------|--|
| 1 Galería de drenaje de la fundación. | 4 Conducto forzado |
| 2 Galerías de acceso. | 5-6 Juntas de contracción longitudinales |
| 3 Losa de hormigón prefabricado | 7 Eje de la presa |

Por último, se tiene en la zona de la estructura de desvío, una presa de gravedad maciza, de 170 metros de longitud y está dividida en 10 bloques independientes. En la misma, se encuentran 4 tomas de agua en su parte superior. En la figura 11 se presenta una sección transversal de la presa de gravedad maciza.



- | |
|---------------------------------|
| 1 Cresta de la presa |
| 2 Cabo de recuperación |
| 3-4 Servomotor |
| 5 Stop log de agua arriba |
| 6 Compuerta de desvío |
| 7 Conducto forzado |
| 8 Pórtico rodante |
| 9 Stop log de aguas abajo |
| 10 Conducto de desvío |
| 11 Compuerta de la toma de agua |
| 12 Eje de la presa |

Figura 11 Sección transversal típica. Presa de gravedad maciza.

En cuanto a la casa de máquinas, de acuerdo a los estudios realizados, se definió situarlo al pie de la presa principal y de la estructura de desvío, figura 12. Tiene una longitud total de 968 metros, una altura de 112 metros y un ancho de 99 metros.



Figura 12 Vista aérea de la casa de máquinas.

La misma aloja todos los equipamientos necesarios para la generación, control y despacho de la energía de la Itaipu. Está dividida en: áreas de montaje en la margen derecha e izquierda, área de montaje central, y por los trechos de la presa principal y el canal de desvío. También, en la misma se encuentra el edificio de operación, la Sala de Control Central, la Sala de Despacho de Energía.

En la figura 13, se presenta un esquema de la casa de máquinas, en la que se muestran algunas de las principales instalaciones. En total, se tienen 20 unidades, que se componen de sus respectivas turbinas, generadores, y transformadores elevadores.

Las turbinas son del tipo Francis, cada una con una potencia nominal de 715 MW. La capacidad instalada de la Central de Itaipu es de 14.000 MW.

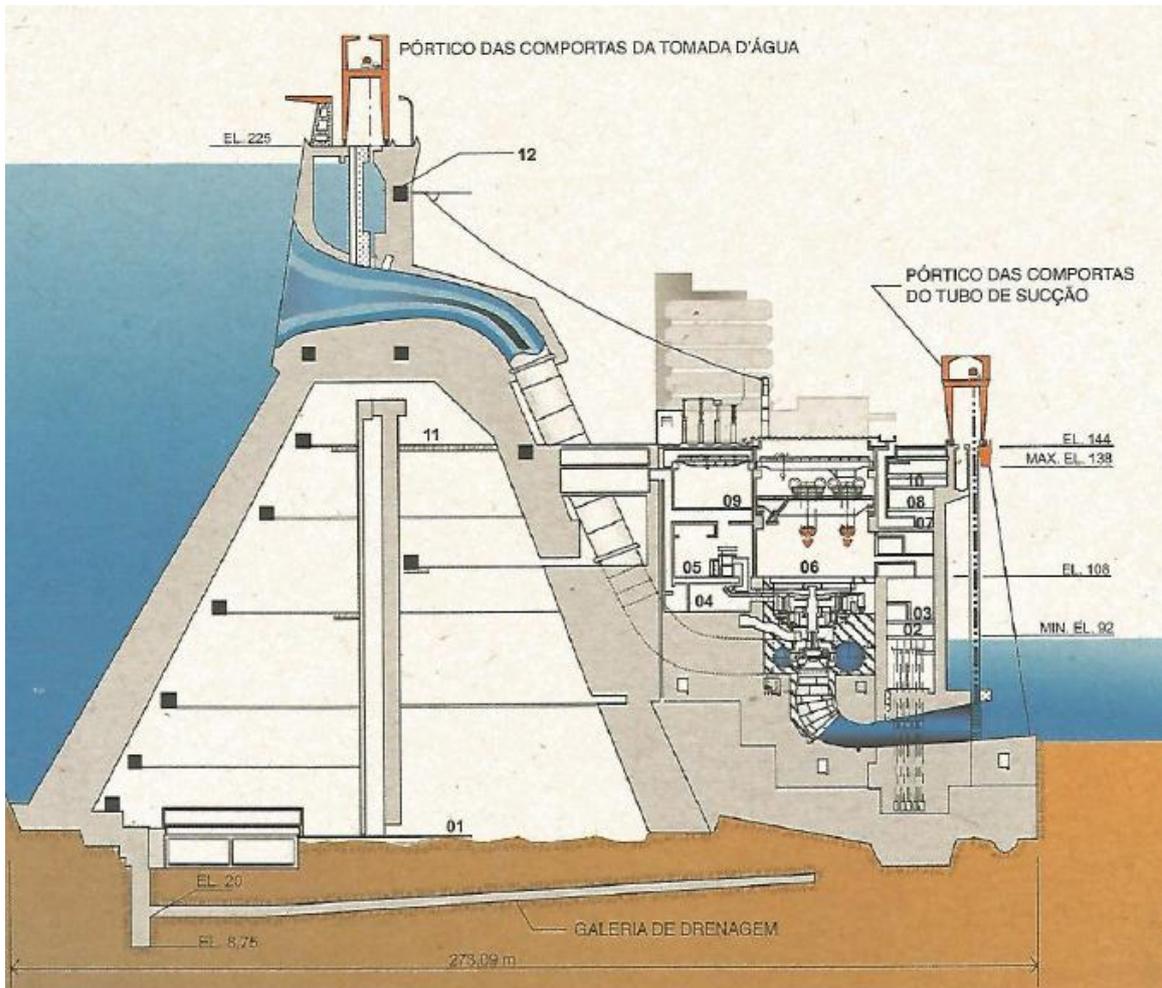


Figura 13 Casa de Máquinas. Ubicación de los equipamientos principales.

- | | |
|--|---|
| 1 Fundación de la presa | 7 Sistema de ventilación |
| 2 Acceso a la turbina | 8 Galería de cables eléctricos |
| 3 Sistema de agua pura | 9 Galería del gas SF6 |
| 4 Sistema de excitación | 10 Sala de generadores diesel |
| 5 Transformadores elevadores | 11 Servicio auxiliar de la presa |
| 6 Piso de las tapas de los generadores | 12 Central hidráulica de las compuertas |

La información técnica, fue en su totalidad extraída del libro Itaipu B. 1994.

2.2. Descripción del Sistema Hídrico de Itaipu

El río Paraná, se origina en territorio brasileño, en la confluencia de dos ríos, el río Grande y el Paranaíba, figura 14. Fluye en sentido sur-oeste, hasta la zona de los Saltos del Guairá, donde da un giro en dirección sur, desde donde se hace frontera entre el Paraguay y el Brasil, a lo largo de 190 km, hasta donde se encuentra con el río Iguazú, y a partir de ese punto se hace frontera entre el Paraguay y la Argentina, para más adelante, aguas abajo, juntarse con el río Paraguay, desde donde vuelve a girar hacia el oeste, y fluye con dirección sur, ya en territorio argentino, hasta encontrarse con el río de La Plata.

Desde su origen, en la confluencia de aquellos ríos principales en el Brasil, hasta su desembocadura en el río de La Plata, el río Paraná tiene aproximadamente 3.500 km de longitud. La cuenca como un todo, abarca un área de alrededor de 3.000.000 km².

La cuenca del río Paraná es una de las mayores redes fluviales del mundo, y su enorme potencial hidroeléctrico, ha sido reconocido desde comienzos del siglo pasado.

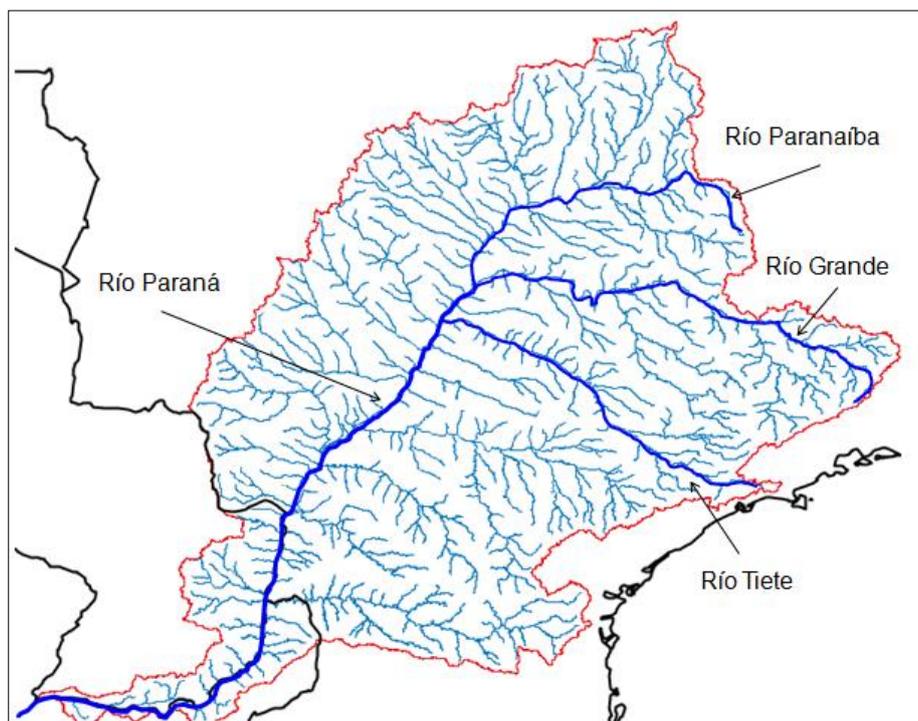


Figura 14 Cuenca del río Paraná con los ríos, Grande y Paranaíba.

Los caudales del río Paraná, están altamente regularizados, por la gran cantidad de presas que se encuentran en toda su cuenca, especialmente aguas arriba de la Itaipu en territorio brasileño, alrededor de 65 centrales hidroeléctricas. Figura 15. Pontes et al. (2012).

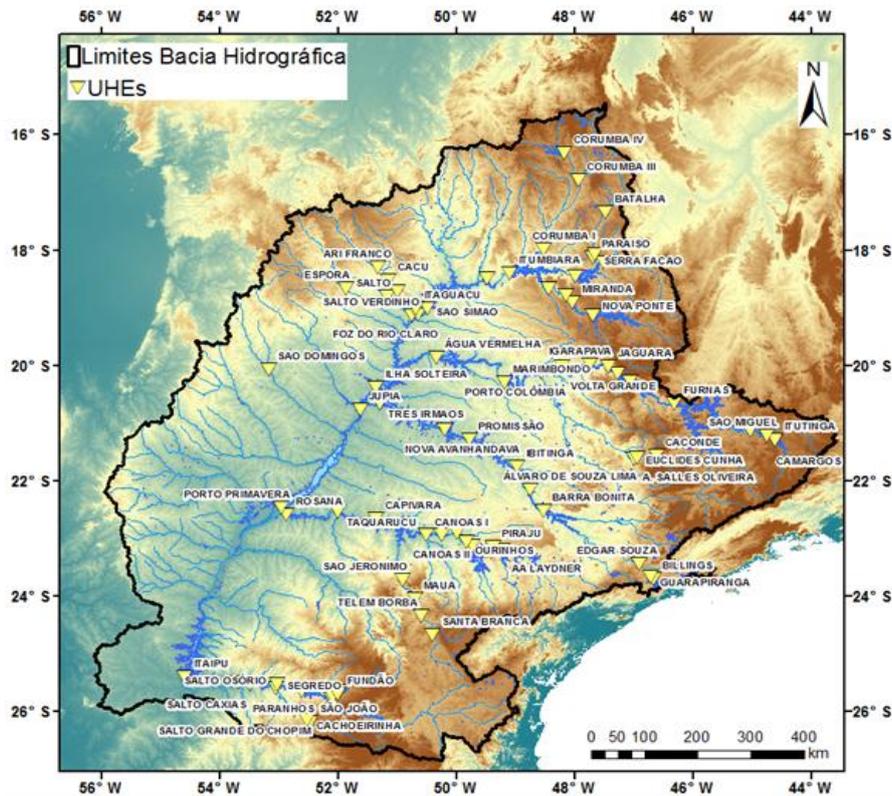


Figura15 Centrales en la cuenca del Río Paraná aguas arriba de la Itaipu.

Pasando al área de interés de la CH Itaipu, la misma está delimitada hacia aguas arriba por la Central Hidroeléctrica de Porto Primavera, sobre el río Paraná, y por la Central Hidroeléctrica de Rosana, sobre el río Paranapanema, que es afluente al río Paraná. A esta área, o cuenca de interés, se la conoce, como cuenca incremental de aguas arriba a la Itaipu.

La cuenca incremental de aguas arriba, posee un área de aproximadamente 150.000 Km², desde las centrales de Primavera y Rosana, hasta la central de Itaipu. Sus afluentes son los ríos Ivaí y Piquirí, San Francisco Falso y San Francisco Verdadero en la margen izquierda, y los ríos Ivinheima, Amambaí e Iguatemi, en la margen derecha, en territorio brasileño. En territorio paraguayo, en la margen derecha, su principal afluente es el río Carapa. Figura 16.

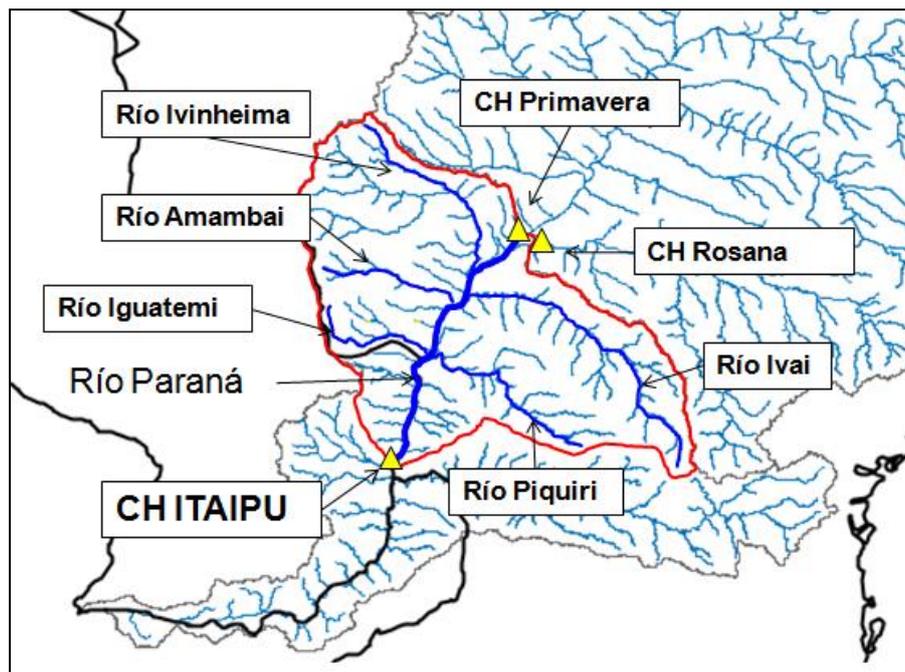


Figura 16 Cuenca incremental de aguas arriba de la Central de Itaipu.

En cuanto a la climatología, esta cuenca, está en una zona de transición entre el clima tropical y sub-tropical del sur del Brasil. También existe una estacionalidad típica de las lluvias del Centro-Oeste del Brasil, y la irregularidad de las lluvias del Sur. No obstante, las lluvias promedio aún representan valores mayores en los meses de verano. El régimen de lluvias en la región, se debe casi exclusivamente a los sistemas de circulación atmosféricas con poca influencia de la topografía sobre las tendencias generales determinadas por los factores dinámicos. RHAMA (2009).

La altimetría de la cuenca, muestra una región más elevada en la cabecera de los afluentes de la margen izquierda, en la cual las altitudes superan los 1.000 metros. Mientras que los afluentes de la margen derecha muestran una declividad bastante inferior. La figura 17 representa el mapa de altimetría de la cuenca incremental de Itaipu, a partir de un modelo numérico del terreno con resolución de 90 metros, RHAMA (2009). La escala de colores representa la altitud en metros.

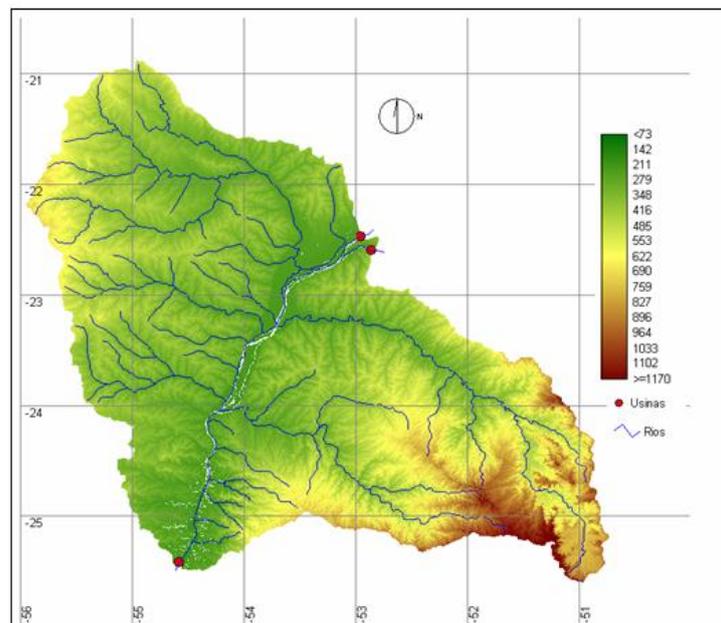


Figura 17 Mapa de altimetrías de la cuenca incremental de la Itaipu.

Por último, en cuanto a la vegetación original de la cuenca, la misma ha sufrido una gran degradación, debido a la deforestación de los bosques, perdiendo muchos árboles, y ampliándose de esa forma las áreas de ganadería y agricultura. Un punto que no puede pasar desapercibido, es que, debida a la situación anteriormente citada, han aumentado los procesos erosivos en gran parte de la cuenca.

A continuación, en la figura 18, se presenta una esquematización del Sistema Hídrico de la Cuenca Incremental aguas arriba de la CH Itaipu, representando los principales componentes del mismo, que son:

- Las Centrales de: Porto Primavera sobre el río Paraná, y Rosana sobre el río Paranapanema.
- Los ríos Ivaí y Piquirí, afluentes al río Paraná por la margen izquierda, y los ríos Ivinheima, Amambaí e Iguatemi, por la margen derecha.
- El embalse de la Central Itaipu.
- Los afluentes por la margen derecha e izquierda al embalse.
- La central de Itaipu.

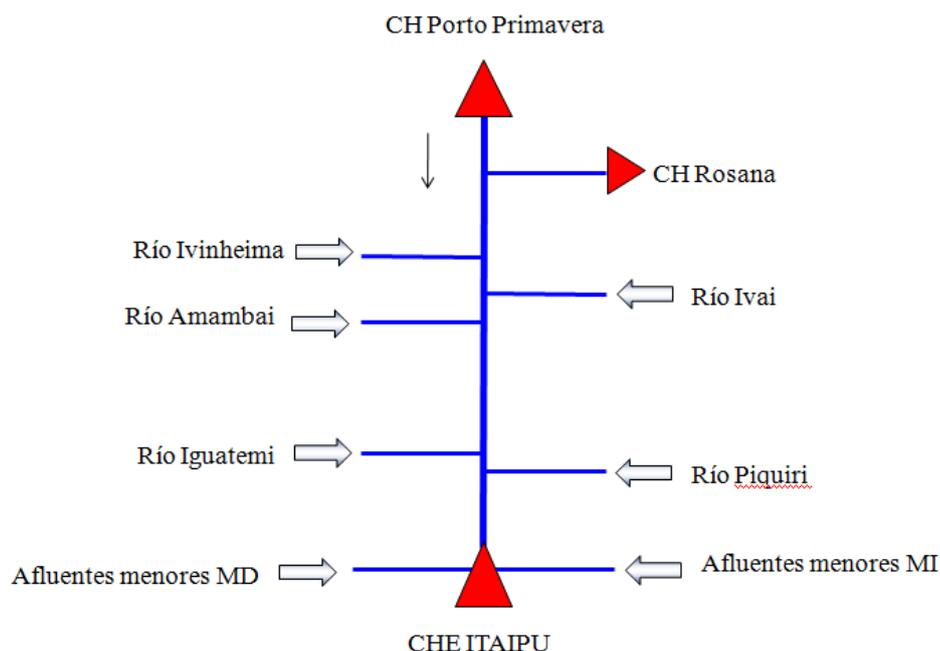


Figura 18 Esquematación del Sistema Hídrico de la Itaipu. Aguas arriba.

A continuación, en la Tabla 1, se citan algunos valores estadísticos (1983/2008) de caudales de los principales ríos afluentes y de las Centrales: (Fuente: OPSH)

Tabla 1 Caudales de Centrales Hidroeléctricas y ríos afluentes al río Paraná. Aguas arriba de la CH Itaipu.

ITEM	DESCARGAS DIARIAS (m ³ /s)		
	MÍNIMO	PROMEDIO	MÁXIMO
Porto Primavera	3672	7274	18626
Rosana	215	1427	10731
Itaipu	5152	11631	38120
RÍOS	CAUDALES DIARIOS (m ³ /s)		
IVAI	79	609	6194
PIQUIRI	64	530	5660
IVINHEIMA	111	370	1836
AMAMBAI	48	138	494
IGUATEMI	64	156	554

En cuanto a la otra área de interés de la Itaipu, la cuenca de aguas abajo, figura 19, la misma, está comprendida, por: la cuenca del río Iguazú, tramo, desde la Central de Salto Caxias, hasta la confluencia con el río Paraná (incluyendo las cataratas del Iguazú), las cuencas de los ríos Acaray y Monday, en territorio paraguayo, y por el río Paraná, tramo desde la Central de Itaipu hasta la estación hidrométrica R11, situada sobre el río Paraná, unos metros aguas abajo de la confluencia con el río Iguazú.

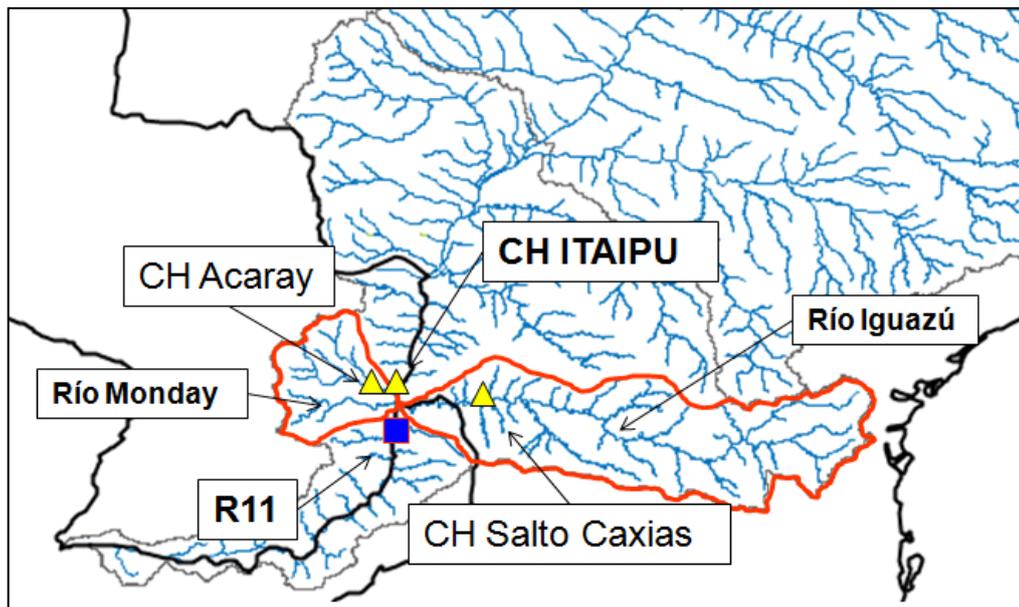


Figura 19 Ubicación cuenca de aguas abajo de la CH Itaipu.

Dicha sección R11, contempla una restricción de variación de niveles del río Paraná, a causa de las descargas de la CH Itaipu, a través de un Acuerdo Tripartito entre Paraguay, Brasil y Argentina.

2.3. La División de Estudios Hidrológicos (OPSH)

La responsable de la previsión de caudales afluentes a la Central Hidroeléctrica de Itaipu, es la División de Estudios Hidrológicos y Energéticos, cuyas siglas son *OPSH.DT*, la cual se encuentra dentro de la Dirección Técnica de la Central, en la Superintendencia de Operación, y dependiendo de forma directa del Departamento de Operación del Sistema.

En la figura 20, se presenta el organigrama de la Dirección Técnica y que muestra donde se encuentra ubicada la OPSH dentro de dicho esquema.

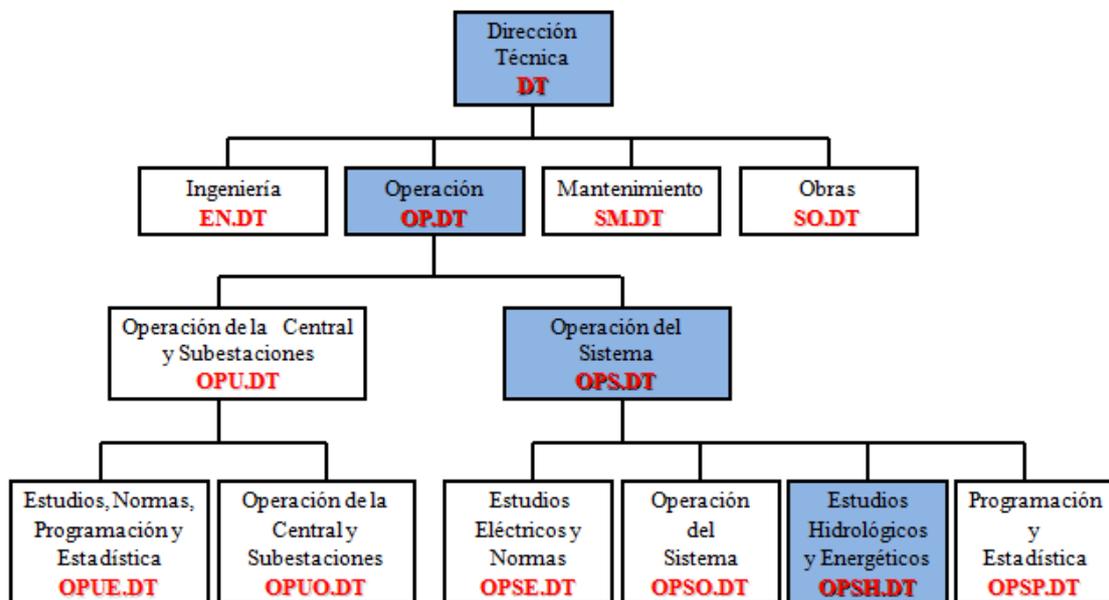


Figura 20 Organigrama de la Dirección Técnica.

Dentro de las funciones que desempeña la OPSH, se rescata la principal, la cual se cita a continuación:

Elaborar la previsión de caudales afluentes, de corto, mediano y largo plazo, para apoyo a la supervisión, programación y planeamiento de la operación energética, dando especial atención a las condiciones en que ocurren variaciones excepcionales de niveles de agua, principalmente en eventos de crecidas.

Para realizar estas y otras tareas y atribuciones, la OPSH, está compuesta por tres sectores: el Sector de Previsión, el Sector de Estudios y el Sector de Campo.

La *tarea rutinaria* de la OPSH, consiste en la emisión diaria de la previsión de caudales afluentes (aguas arriba) al embalse de la Itaipu, así como también de los caudales incrementales aguas abajo en la estación hidrométrica de R11, ambos en un horizonte de 10 días, considerando al día actual.

También, debe emitir una previsión a mediano plazo, y dentro de los primeros 5 días hábiles del mes, el *Informe Hidrológico Mensual (IHM)*, el cual se divide en dos partes bien diferenciadas: la primera presenta lo ocurrido en el mes inmediatamente pasado; y en la segunda, se presentan las predicciones del mes corriente, tanto en los caudales afluentes de aguas arriba y de aguas abajo, contemplando las descargas de las centrales de aguas arriba y de aguas abajo, los caudales de la cuenca incremental aguas arriba y aguas abajo.

Por último, se emite también, una previsión de largo plazo, denominado Informe de Supervisión Hidrometeorológica, el cual estima los caudales para el trimestre siguiente, en el cual se tiene en cuenta ya, las condiciones climáticas a escala regional, que podrán tener impacto en los meses siguientes. Se evalúan las condiciones relacionadas al fenómeno de El Niño y/o La Niña, y sus posibilidades de apariciones con sus posibles impactos, principalmente en las áreas de interés de la Itaipu.

Todas estas previsiones de corto, mediano y largo plazo, son enviadas al área de Programación de la generación eléctrica, para que sirva de apoyo a la toma de decisión justamente en la generación, ya sea, en corto, mediano y largo plazo, cada uno de ellos atendiendo a las demandas de energía de ambos países.

3.Redes Neuronales Artificiales (RNA).

3.1.Inspiración biológica de las RNA.

Como en muchas situaciones, y no solo en el campo científico, sino que en cualquier situación de la vida, que se presenta esa *curiosidad*, para seguir adelante, en el buen sentido de la palabra, para tratar de descubrir y entender por sobre todo, algunas cosas, que pueden ser, por ejemplo, procesos desde los más simples hasta los más complejos, inclusive en situaciones muy cotidianas, que llevan a una persona a realizar las tareas más sencillas o de poca importancia, que las ejecutamos hasta sin darnos cuenta, pero que nuestro cerebro, ordena a todo nuestro cuerpo a ejecutarlo.

Precisamente, una de esas *curiosidades*, ha llevado a científicos a tratar de interpretar los mecanismos de funcionamiento de nuestro cerebro, responsable este, por todos nuestros actos, conscientes e inconscientes. Esa curiosidad, por la rapidez y eficiencia con la que el cerebro humano realiza todas sus innumerables funciones, ha sido el objeto de estudio de estos científicos, iniciados desde hace varios años atrás, inclusive a finales del siglo XIX, y que en la actualidad ha evolucionado en lo que hoy se llama *Inteligencia Artificial (IA)*, el cual se basa en las simulaciones computacionales de aspectos de la inteligencia humana, en la cual se ha tratado de representar por medio de programas computacionales, el funcionamiento del proceso de aprendizaje del cerebro humano.

El cerebro humano, consiste en un gran número (aproximadamente 10^{11}) de elementos altamente conectados (aproximadamente 10^4 conexiones por elemento), denominados neuronas. Hagan et. al (1996).

Para propósitos nuestros, estas neuronas, están compuestas de tres partes principales: las dendritas, el cuerpo de la célula y el axón con sus terminaciones, figura 21. Las dendritas, son redes de fibras nerviosas receptoras, que llevan o transmiten los impulsos eléctricos dentro del cuerpo de la célula. El cuerpo de la célula, suma y limita efectivamente estos impulsos entrantes. Por último, el axón, es una fibra larga y única, que transmite el impulso, desde el cuerpo de la célula, hacia otra neurona.

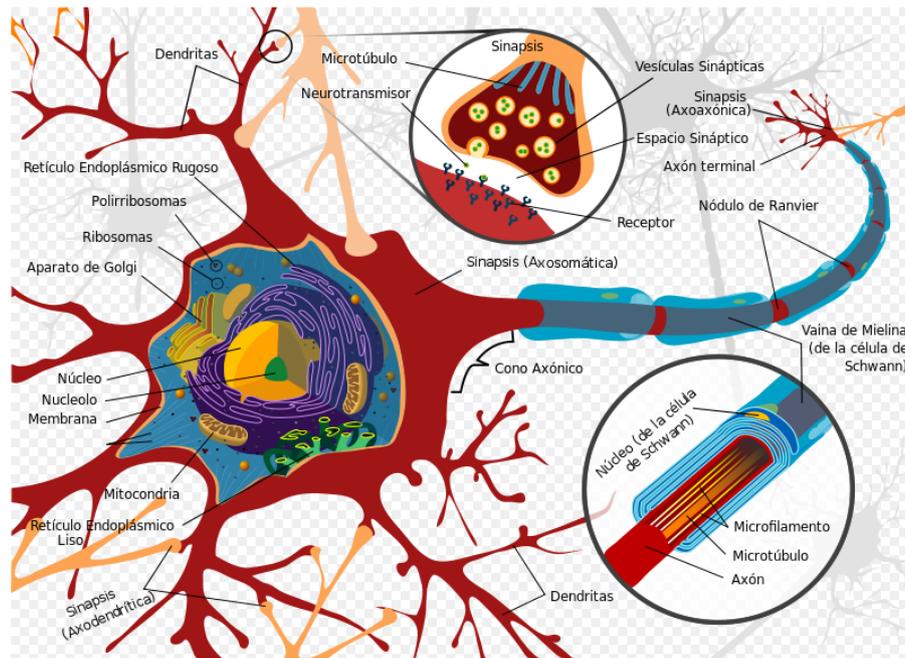


Figura 21 Componentes de una neurona biológica. Fuente: Wikipedia.

El punto de contacto entre el axón de una célula y la dendrita de otra célula, es llamada sinapsis. Una característica fundamental de la mayoría de las sinapsis, es que la propagación de la señal es en una sola dirección, esto permite que los impulsos sean conducidos en las direcciones adecuadas al desempeño de las funciones nerviosas necesarias. Dos Santos (2001). El conjunto de todas las neuronas y las respectivas sinapsis, forman una gran red, denominada red neuronal.

Las sinapsis desempeñan una acción selectiva, usualmente, bloquean las señales débiles, pero permiten el paso de las señales más fuertes, seleccionando y amplificando ciertas señales débiles, y canalizando las señales en varias direcciones, esto lo hace a través de impulsos. Un impulso recepcionado por una neurona X, es procesada y al sobrepasar un límite de acción, se dispara un segundo impulso, el cual produce una sustancia neurotransmisora, la cual fluye, del cuerpo de la célula, hacia el axón, que puede estar conectado a una dendrita de otra neurona.

Dos tipos de fenómenos están envueltos en el procesamiento de un impulso: el eléctrico y el químico. Los impulsos eléctricos, propagan una señal dentro de la neurona por medio de canales directos, conduciendo los mismos, de una célula a otra, transmitiendo la señal en cualquier dirección. Los procesos químicos,

transmiten la señal de una neurona a otra, y se generan al final del axón, en la sinapsis. El axón libera sustancias químicas, que son los neurotransmisores, los cuales se unen a receptores químicos en la membrana de la siguiente neurona. De forma distinta a los impulsos eléctricos, los químicos, transmiten la señal en sentido único, o sea, de la neurona emisora a la neurona receptora.

La membrana que envuelve la parte externa del cuerpo de la neurona, genera impulsos eléctricos, la cual es una función vital del sistema nervioso y del central. El cuerpo a su vez, combina las señales recibidas y, si el valor resultante está por encima de un valor límite de excitación de la neurona, un impulso eléctrico es producido y propagado a través del axón hacia las siguientes neuronas. La neurona puede controlar la frecuencia de los impulsos, aumentando o disminuyendo la polaridad en la membrana pos-sináptica, inhibiendo o estimulando la generación de los impulsos de una neurona a otra. Ese control determina el funcionamiento, el comportamiento y el raciocinio del ser humano.

Biológicamente hablando, una neurona pasa adelante un estímulo conforme la intensidad de los estímulos recibidos, provenientes de las neuronas que están conectadas a ella. En el mundo artificial, el mismo efecto es simulado, dentro de las posibilidades tecnológicas. Justamente, en este mundo artificial, los científicos habían iniciado los primeros estudios sobre el funcionamiento del cerebro humano a finales del siglo XIX e inicios del siglo XX.

En 1943, el neurofisiólogo Warren McCulloch y el matemático Walter Pitts, desarrollaron la primera analogía entre el comportamiento de la célula neuronal viva y los procesos electrónicos. El trabajo consistió en un modelo de resistencias variables y amplificadores, representando las conexiones sinápticas de una neurona. Luego en 1949, el psicólogo Donald Hebb, publicó su libro: *The Organization of Behavior*, en el que postuló las bases del aprendizaje de las RNA, cuando explicó lo que ocurre, a nivel celular, durante el proceso de aprendizaje del cerebro humano. Hebb propuso la utilización de pesos como forma representativa de que las RNA puedan asimilar el conocimiento. La introducción de la idea de los pesos como forma de aprendizaje de las RNA, permitió, que en el año 1951, Marvin Minsky, construyera el primer neuro-computador, pero aún sin ninguna utilidad práctica.

A finales de la década de los 50, Frank Rosenblatt, concibió a la primera RNA, denominada Perceptron, de una capa, con la capacidad de aprender e identificar patrones conforme las reglas impuestas por Hebb. En 1960, Widrow y Hoff, desarrollaron la red *ADALINE (ADaptive LINear Elements)*, la cual por primera vez fue utilizada para resolver un problema real, ecos en las líneas telefónicas. En 1969, Marvin Minsky y Seymour Papert, publicaron un libro llamado *Perceptrons*, en el cual criticaron seriamente las investigaciones sobre RNA, definiendo a las mismas como caminos sin salida. El impacto de esa publicación fue fatal, con las críticas, las investigaciones sobre RNA, se paralizaron, casi hasta el año 1982.

No fue sino hasta los inicios de la década de los 80, donde de nuevo las mayores contribuciones a la teoría y diseño de las RNA fueron hechas en varios frentes, con lo que hubo un resurgimiento del interés hacia las RNA. En 1982, Hopfield, establece una clase particular de redes neuronales, con la llamada retro-alimentación, la cual atraería gran interés de nuevo en las RNA. También, en este mismo año, Kohonen, presenta su trabajo sobre los *Self-Organizing Maps (SOM)*.

Pero en el año 1986, lo que impulsó e incentivó a seguir con las investigaciones de RNA, fue la presentación del trabajo de Rumelhart, Hinton y Williams, sobre el Algoritmo de Retro-propagación. En el mismo año, Rumelhart y McClelland, publican el libro *Parallel Distributed Processing: Explorations in the Microstructures of Cognition*, el cual fue de gran influencia en el uso del aprendizaje del algoritmo de retro-propagación.

A modo de un último rescate histórico, en este recuento histórico presentado, nos queda mencionar un trabajo presentado en el año 1989 por Funahashi, *On the Approximate realization of continuous mappings by neural networks*, en el que demuestra que con una red neuronal alimentada hacia adelante, con tres capas (una sola capa oculta) con suficiente número de nodos en la capa oculta, y entrenada con el algoritmo de retro-alimentación, es capaz de aproximar cualquier función continua, con el grado de precisión solicitado.

3.2. Descripción de las RNA.

En este ítem del TFM, se presenta una breve descripción acerca de algunas definiciones de las RNA, entresacadas de diversos autores. Este TFM no pretende ser extenso en esto, ya que existen en plaza diversos libros en los que se puede encontrar desde los principios básicos hasta los más complejos sobre RNA. A seguir, unas breves y concisas definiciones de RNA.

Según Haykin (1999), las Redes Neuronales Artificiales son máquinas diseñadas para modelar la forma en que el cerebro humano ejecuta una tarea particular o una función de interés. Las mismas, para emular esas tareas, se basan en un proceso de aprendizaje. Para alcanzar un buen desempeño, las RNA, emplean unas interconexiones en grandes cantidades, de células de cálculos simples, denominadas *neuronas* o *unidades de procesamiento*.

El mismo autor, se refiere finalmente a la siguiente definición de RNA:

Una RNA, es un procesador distribuido paralelo de forma masiva, constituido de unidades de procesamiento simple, las cuales tienen una capacidad natural de almacenar conocimiento experimental y de ponerlo disponible para su uso.

Matemáticamente, una RNA, es normalmente vista como un aproximador universal de funciones. Tienen la habilidad de identificar relaciones de unos patrones dados para resolver problemas complejos a gran escala, como ser: reconocimiento de patrones, modelación no-lineal, clasificación, asociación y control. Govindaraju (2000a).

Las RNA son modelos computacionales inspirados biológicamente, las cuales están basadas en la forma en que funciona el cerebro humano. Son desarrolladas entrenando a la red para representar las relaciones y procesos que se encuentran en forma inherente dentro de los datos. Siendo esencialmente modelos de regresión no-lineales, ellos ejecutan un mapeo *input-output*, utilizando un conjunto de nodos de procesamientos simples interconectados o neuronas. Solomatine (2008).

Las RNA, han sido desarrolladas como generalización de modelos matemáticos del funcionamiento del cerebro humano. Su desarrollo está basado en las siguientes reglas presentadas en Govindaraju (2000a):

- El procesamiento de la información ocurre a través de muchos elementos simples denominados nodos, también llamados como unidades, células o neuronas.
- Las señales pasan entre los nodos a través de los enlaces de las conexiones.
- Cada enlace de conexión tiene asociado un peso que representa la fuerza de la conexión.
- Cada nodo, típicamente aplica una transformación no-lineal, denominada función de activación (FA) a su *input* de la red para determinar su señal de *output*.
- La unidad básica, denominada neurona, es una unidad de procesamiento de información y es la parte fundamental de las RNA. La Figura 22 presenta las partes componentes de la neurona artificial del tipo Perceptron, descrita en Haykin (1999), y la cual está constituida, en este ejemplo por varios elementos de entrada.

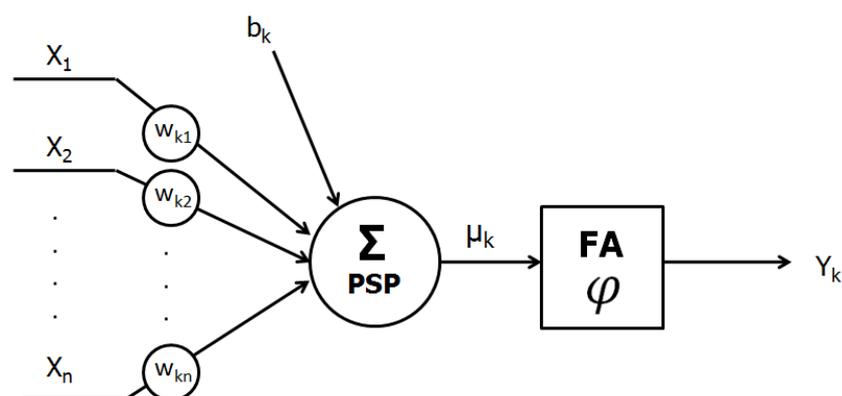


Figura 22 Neurona Artificial. Fuente: Adaptado de Haykin 1999.

donde:

X_1, X_2, \dots, X_n datos de entrada

$W_{k1}, W_{k2}, \dots, W_{kn}$ pesos sinópticos

b_k umbral de activación

μ_k salida del PSP

FA Función de Activación

A seguir, una breve descripción de los componentes y funciones de esta neurona artificial de la figura 23.

Los datos de entradas o *inputs* son los valores X_1, X_2, \dots, X_n los cuales son presentados a la neurona, la cual recibe y procesa a estos a través de una función denominada PSP (*Post Synaptic Potencial*), que es una función del tipo combinación lineal, ecuación (1), entre los datos de entrada X_n y los pesos sinópticos W_{kn} que son números reales:

$$\sum_{j=1}^n W_{jk} \cdot X_j - b_k = \mu_k \quad (1)$$

Luego, una vez emitida la señal de salida de la neurona μ_k , se ejecuta la función de activación (FA), representada por φ , que es función de la salida μ_k y la cual calcula la señal de salida de la neurona.

Existen varias FA en la literatura, y son seleccionadas en función al problema a ser resuelto, las más utilizadas son: las funciones sigmoides, ecuación (2), y son de la forma:

$$\frac{1}{1 + e^{-aX}} \text{ o } \frac{2}{1 + e^{-aX}} - 1 \quad (2)$$

según sean acotadas a los intervalos $[0,1]$ o $[-1,1]$.

Un caso particular es cuando en la ecuación (2) el valor del parámetro $a=1$, y resulta la *función logística*, ecuación (3):

$$\frac{1}{1 + e^{-x}} \quad (3)$$

Otro caso particular es cuando en la ecuación (2) el valor del parámetro $a=2$, resultando en la *función tangente hiperbólica*, ecuación (4):

$$\frac{2}{1 + e^{-2x}} - 1 \quad (4)$$

También se encuentran funciones del tipo escalón, rampa e identidad.

A continuación, siguiendo con la descripción de las RNA, es detallado en los siguientes párrafos, lo que se refiere a la arquitectura de la red, y se han clasificado principalmente según Hagan (1996) en:

- la unidad de neurona de un solo *input*.
- la unidad de neurona, del tipo *Perceptron*, de dos capas (descrita más arriba) y con varios *inputs*.
- la RNA del tipo *Multilayer Perceptron* (MLP) de varias capas y con varios *inputs*.
- las RNA del tipo Recurrente.

Las redes más conocidas son las del tipo MLP, y son formadas por un conjunto de neuronas colocadas en capas (*layers*), típicamente se componen de, una capa de entrada, una o varias capas intermedias y una capa de salida. Cada una de las neuronas de la capa de entrada están conectadas a las neuronas de la capa intermedia, y de igual forma, las neuronas de esta, están conectadas a todas las neuronas de la capa de salida.

Una característica importante de las RNA del tipo MLP, es que la información se propaga en un solo sentido, o sea, una vez que los datos de entrada son presentados a la red en la capa de entrada, la información a partir de ese momento se propaga en el sentido hacia la capa de salida, a esto se lo denomina *feedforward*. Cada neurona de una capa intermedia, recibe una combinación lineal (PSP) de los datos de entrada, y la cual genera la entrada para la función de activación, la cual a

su vez genera un estímulo de salida, ya sea para otra capa intermedia o para la capa de salida o neurona de salida.

Los pesos, son ajustados durante el proceso de *entrenamiento* o *calibración* que será explicado en 3.3, y cuyo objetivo es el de minimizar los errores de las salidas u *outputs* de la red.

3.3. Entrenamiento de una RNA.

Al ajuste de los *pesos* que componen una red neuronal, como fue mencionado más arriba, se lo denomina *entrenamiento* o *calibración*. En un sentido más general, este ajuste se refiere a la minimización de los errores de las salidas u *outputs* de las RNA, y el mismo se basa en la solución de un problema de optimización.

El algoritmo que devolvió a las RNA su preponderancia, que ha servido para revitalizarlas, y el cual es el principalmente utilizado en las redes MLP, es el denominado de *backpropagation*, que fue presentado por Rumelhart, Hinton y Williams en el año 1986. Cabe resaltar, que esta metodología ya había sido elaborada por Werbos en el año 1974, en la Universidad de Harvard.

Este algoritmo, como lo dice su nombre, *propagación hacia atrás*, lo que realiza es, que los errores resultantes al final de la capa de salida, los reintroduce en la capa de entrada. Luego, el algoritmo modificará convenientemente los pesos de la red en las iteraciones siguientes a modo de ir reduciendo al mínimo el error. En forma más general, lo que realiza es la búsqueda de un mínimo global de una función de error.

La búsqueda de un mínimo o un máximo (problema de optimización) está compuesta por una función objetivo y por ecuaciones o inecuaciones de restricciones. La función objetivo puede ser de forma lineal, no lineal monovariante y no lineal multivariante. Las funciones lineales y no lineales monovariantes son representadas por líneas y curvas en el plano, mientras que las multivariantes son representadas por superficies en tres o más dimensiones, según sean sus números de variables independientes.

En forma general, el problema de optimización habitual en las RNA, tiene la siguiente expresión de la ecuación (5):

$$\text{Min } FO = \frac{1}{2n} \sum_{j=1}^n [e^{(j)}]^2 \quad (5)$$

donde:

FO es la Función Objetivo.

$e^{(j)}$ es el error a minimizar y es igual a : $(y_{\text{calc}} - y_{\text{obs}})$

y_{calc} es la salida calculada de la función.

y_{obs} es la salida observada.

El proceso de entrenamiento, puede ser tedioso, complejo, ya que en las redes pueden encontrarse complicaciones de diversas índoles, como ser, mínimos locales, lugares planos, etc., lo que dificultaría encontrar el mínimo global. Matemáticamente lo que hacen los algoritmos de entrenamiento es proveer un método eficiente para obtener las primeras derivadas de la función objetivo en relación a los pesos y a los umbrales.

Otro método, conocido para entrenar RNA, es el de *Levenberg-Marquardt*, que es una variación método de Newton que fue diseñado para minimizar funciones que son los cuadrados de la suma de otras funciones no-lineales. Según Hagan et al. 1996, este método es muy adecuado para entrenamientos de RNA en el que la función a minimizar es el error cuadrático medio. En el ambiente de las RNA las redes que utilizan este tipo de algoritmo se les llaman redes *Levenberg-Marquardt Back propagation* (LMBP).

El LMBP requiere más capacidad computacional por el tipo de solución que el mismo ejecuta, pero requiere menos números de iteraciones para converger en comparación con otros algoritmos y aunque necesita de más capacidad computacional aparenta ser el método más rápido de todos para entrenamientos de RNA con número moderado de parámetros, según Hagan et al. (1996). Los mismos autores, sobre el uso del algoritmo LMBP, recomiendan tener en cuenta a la hora de

utilizar este el número de parámetros, de unos miles aproximadamente, a efectos de que los cálculos computacionales no vuelva impracticable al algoritmo.

3.4. Modelación Hidrológica con RNA.

Las RNA, como se ha visto hasta este punto, pueden ser utilizadas en varios contextos, en el que se requiera realizar predicciones o reconocimiento de patrones, en ambos casos a través de datos de entradas, conocidos como predictores, que sirven de información para calcular lo que se quiere predecir.

En lo que se refiere a la modelación hidrológica, en el cual se pretende establecer una relación entre la lluvia ocurrida en la cuenca y el caudal generado por la misma, en un punto del río en dicha cuenca, para los ingenieros hidrólogos, es de vital importancia el conocimiento de esta relación, para el establecimiento de una obra, que puede ser desde una simple alcantarilla hasta la construcción de una presa o para gerenciar un proyecto.

Esta relación lluvia-caudal, en una cuenca, es muy compleja, ya que no solamente depende de ellos, si no, también depende de otros factores, como son la humedad inicial del suelo, el uso del suelo, geomorfología de la cuenca, evaporación, infiltración, distribución y duración de la lluvia, etc., según Govindaraju (2000^a).

En lo que a predicción de caudales se refiere, varias técnicas han sido desarrolladas y utilizadas. Básicamente se las puede clasificar en dos; las estadísticas/estocásticamente basadas y las físicas/conceptualmente basadas.

Las primeras, se basan en que los caudales están relacionados exclusivamente en términos estadísticos o estocásticos a factores hidrológicos y climáticos, como lo son las lluvias o temperaturas.

Los segundos, son modelos basados en expresiones matemáticas que tratan de describir los procesos físicos del ciclo hidrológico que ocurren en una cuenca. Estos a su vez se vuelven a dividir en función al tiempo de simulación, es decir, modelos que simulan solo tormentas de cortas duración, son conocidos como

modelos de eventos, y por otro lado, los modelos que simulan en forma continua los eventos, como ser de sequías o crecidas, estos son conocidos como modelos continuos. También, otro aspecto importante de estos modelos físico/conceptuales, es la forma en que discretizan la cuenca, o sea, en como son considerados los parámetros dentro de la cuenca, y por sobre todo en cómo obtener información de estos. Se los clasifica como concentrados o distribuidos. Los concentrados asumen a la cuenca divididos en áreas menores (sub-cuencas), por lo tanto se consideran los parámetros iguales para todas esas sub-cuencas. Los distribuidos, en cambio consideran a la cuenca dividida en función de la resolución utilizada por el modelo digital de elevación del terreno, con ayuda de los Sistemas de Información Geográfica, para el tratamiento de la información espacial (uso y tipo de suelo), y para la estimación de los parámetros, en función a la resolución mencionada.

Dentro de este contexto, hace unos años atrás son aplicadas las RNA, a partir de su gran desarrollo a inicios de la década de los 90 y de la mano con el desarrollo acelerado de la capacidad computacional de ejecutar los cálculos, han favorecido a la aplicación de las RNA, no solo en la hidrología, sino en diversas áreas en la que se debe realizar predicciones de diferentes índoles.

La modelación de la relación lluvia-caudal, ha sido quizás lo que más ha recibido atención por parte de los modeladores (ingenieros hidrólogos) de RNA, y ha llevado a la realización de muchos trabajos (como son presentados en el Capítulo 4 de este TFM). La propia naturaleza no-lineal de la relación lluvia-caudal, disponibilidad de registros históricos extensos, complejidad de la implementación de modelos físicamente basados, conocimiento exhaustivo de la cuenca, entre otros factores han llevado a los investigadores a fijarse en modelos alternativos, en las cuales las RNA han sido la alternativa lógica. Govindaraju (2000b).

Otro aporte en este aspecto es el de Dawson y Wilby (2001), en el que exponen que el uso de las RNA, no presupone un conocimiento detallado de las características de la cuenca, ni requiere un preprocesamiento de datos muy extenso. Aún más, las RNA, son usualmente más baratas y simples de implementar que lo que sería su equivalente de modelos físicamente basado. Además, superficialmente, las RNA, proporcionan una solución original e interesante al problema de la relación entre *inputs* y *outputs* en un sistema complejo.

Sin embargo, los mismos autores, también ponen a consideración, a tener en cuenta que además de esas ventajas citadas más arriba, las RNA, presentan algunas desventajas, como lo son la falta de coherencia de algunos abordajes y la práctica pobre de modelación existente aún.

Justamente, por ejemplo, una de las críticas hacia los modelos hidrológicos de RNA es sobre su incapacidad de predecir valores por fuera del rango de valores máximos de su conjunto de datos usados en la etapa de entrenamiento, para lo cual se puede plantear la estandarización de datos (presentada en 5.2 de este TFM) es muy importante para acomodar los posibles valores superiores de los conjuntos de datos del test y de la validación, en comparación a los del entrenamiento, de acuerdo a Dawson et al. (2002).

En el caso de las predicciones hidrológicas, o sea, de la determinación de las relaciones lluvia-caudal en una cuenca determinada, se tiene la siguiente expresión básica de la ecuación (6) presentada por Dawson et al. (2001):

$$Q_t = f(Q_{t-n}, R_{t-n}, X_{t-n}) \quad (6)$$

donde:

Q_tes el caudal actual a predecir

Q_{t-n}es el caudal antecedente para los pasos de tiempo t-1, t-2,...t-n

R_{t-n}es la precipitación antecedente para los pasos de tiempo t-1, t-2,...t-n

X_{t-n}es cualquier otro predictor de Q_t identificado como preponderante.

Evaluando esta ecuación, se puede concluir, que lo que debe ser determinado en un inicio, es el paso de tiempo, n óptimo de cada uno de los predictores de la variable a predecir.

Para ello, desarrollar una metodología para el análisis de los datos, es muy importante a la hora de determinar los *inputs* más apropiados para iniciar la modelación con RNA y también el tiempo de antecedencia n , en los que, en la mayoría de los casos, se usan las condiciones antecedentes en la cuenca, según

Dawson et al. (2001). El mismo, presenta, como alternativa a metodologías de modelos auto-regresivos de media móvil (ARMA), un método basado en análisis de correlación, entre la variable a predecir y las predictoras, para identificar las relaciones más fuertes entre las mismas.

4. RNA para predicción de caudales: Antecedentes

Antes de iniciar cualquier investigación, en una determinada área, siempre y en todos los casos que sean, se deben buscar y analizar investigaciones anteriores y actuales, ya sean en formatos de libros de textos de referencias, artículos técnicos, información de empresas vinculadas al sector objeto de estudio, y también, información disponible en la web, pero siempre en este caso, atendiendo a la fuente de referencia del mismo.

Esta búsqueda, es sumamente necesaria, e inclusive es preponderante en lo que se refiere a RNA, ya que no existe una metodología única o padronizada, o al menos hasta este momento, en el cual se establezcan los pasos fijos a seguir para desarrollar modelos de predicción hidrológica con RNA. Por lo tanto, es de mucha utilidad a la hora de iniciar el estudio, para tener claro hacia dónde ir y como, y hasta qué punto llegar, y no quedar atascado entre todas las posibilidades existentes, de cómo modelar con RNA.

En este TFM, se presenta un resumen de la amplia literatura sobre modelación hidrológica, con los artículos relacionados sobre este tema, en los cuales se han utilizado las RNA como herramientas de predicción, y en este caso específico, en lo posible a escala mensual.

El primer material sobre RNA que estuvo a mi alcance, fue el García-Bartual (2005), el cual ha sido el libro de texto utilizado en la cátedra de Redes Neuronales Artificiales en Ingeniería Hidráulica impartida dentro del MIHMA de la UPV. El mismo presenta los fundamentos de las RNA, aplicaciones y recomendaciones para sus aplicaciones en diversos campos de la Ingeniería.

Una vez que, habiendo tomado la decisión de modelar hidrológicamente una cuenca, desde lo que se refiere el proceso lluvia-caudal, y en particular atendiendo a la necesidad de la OPSH de tener una herramienta para estimar caudales mensuales, se ha recurrido a libros de textos para ir complementando los conocimientos ya adquiridos, como ser el libro *Neural Networks: A Comprehensive Foundation* de Haykin (1999), sobre conceptos teóricos de RNA. Otro libro de referencia utilizado fue el *Neural Network Design*, de los autores Hagan et al. (1996).

También para referencia sobre conceptos teóricos de RNA se ha utilizado el trabajo de Solomatine et al. (2008).

Continuando con la revisión de conceptos teóricos sobre RNA, Govindaraju, Rao S. (2000a) y (2000b), presenta en dos artículos denominados *Artificial Neural Networks in Hydrology*. La parte I sobre Conceptos Preliminares, en el cual, el autor presenta conceptos teóricos básicos de RNA, métodos de entrenamientos, aspectos útiles de modelación con RNA, diseño y recomendaciones finales al respecto. En la parte II que trata sobre Aplicaciones Hidrológicas, el autor presenta varias posibilidades de aplicaciones de las RNA en varias ramas de la hidrología, como son, predicción de caudales, calidad de agua, aguas subterráneas, estimación de precipitaciones y otros. También, en la última parte de esta, presenta un análisis interesante sobre el futuro de las aplicaciones de RNA en hidrología y su vinculación con procesos físicos en la cuenca.

Todos los libros y artículos presentados hasta este momento, han servido de referencia, como ya se había mencionado, para consolidar la base teórica en cuanto a las definiciones, conceptos y aplicaciones sobre RNA en predicciones de caudales en ríos. En los siguientes párrafos, se presentan una descripción de los artículos que fueron utilizados de referencia, para cada una de las partes en lo que al proceso de desarrollo de las RNA, y en cuanto a su aporte específico de cada uno de ellos se refiere a este TFM.

Como punto de partida, se han buscado artículos que hagan referencia, a predicciones de caudales, y que aborden la problemática que ello envuelve, en cuanto a consideraciones a tener en cuenta para la selección de predictores, tipo de red y de algoritmo de entrenamiento de la RNA.

Dentro de lo que fue este primer punto de partida, mencionado en el párrafo anterior, el primer artículo que despertó mi interés en una aplicación concreta de RNA a predicciones de caudales vinculados a una Central Hidroeléctrica, fue el de Dawson et. al (2002), los cuales utilizaron RNA para predecir caudales afluentes horarios del río Yangtze, al embalse de la represa de Tres Gargantas en China. Evaluaron dos tipos de RNA, la famosa MLP y la RBF. Como predictores fueron utilizados caudales en dos estaciones aguas arriba de la represa, siendo una de

ellas en la represa misma, y datos de precipitaciones de 4 pluviómetros en la cuenca de aguas arriba. El entrenamiento fue realizado con el algoritmo del backpropagation y fue realizado un proceso de *prueba y error* para la determinación del número óptimo de nodos en la capa oculta, utilizando 5, 10, 20 y 30 nodos en la capa oculta. Sus conclusiones más importantes han sido que no siempre la red de mejor desempeño es la MLP, en este caso resultó ser la RBF, y la otra conclusión es que las RNA pueden predecir eventos más allá de los valores utilizados en el entrenamiento.

Buscando otros artículos de estos autores, se debe destacar a un artículo en particular, que ha mas del citado en el párrafo anterior, ha servido de referencia en este TFM en muchos aspectos, especialmente a la hora de iniciar el trabajo con RNA aplicadas a las predicciones de caudales; el *Hydrological modelling using Artificial Neural Networks* de Dawson y Wilby (2001), en el que presentan, una introducción teórica de RNA y una parte que puede servir de mucha ayuda, principalmente para aquellas personas que se están iniciando en el mundo de la modelación hidrológica con RNA, y es su *Protocolo de Implementación de modelos hidrológicos*, en el que proponen 7 pasos a seguir para implementar un modelo de RNA aplicado a hidrología. En el capítulo 5 de este TFM, se presenta la metodología utilizada la cual se ha basado en este protocolo.

A continuación, se han recurrido a artículos que han utilizado RNA y que específicamente como variable a predecir caudales mensuales, ya que unas de las condicionales de trabajar con este horizonte temporal de predicción es el de contar con un número suficiente de meses anteriores para poder realizar el entrenamiento y la verificación, por lo que evaluar lo utilizado por otros autores en este aspecto ha sido de mucha utilidad. Autores como Anmala et. al (2000); Cárdenas y Gil (2000); Dolling y Varas (2001); Garbrecht (2006); Jaime y Menéndez (2003); Nilsson (2006); Ochoa (2002); Póveda et. al (2002); Prada-Sarmiento y Obregón-Neira (2009), han realizado predicciones de caudales mensuales utilizando diferentes predictores en cada caso.

Una parte muy importante dentro del TFM, fue decidir que predictores utilizar, teniendo en cuenta el horizonte que se ha seleccionado para predecir, el mensual, el cual tiene algunas particularidades. En este punto en particular, se han encontrado

alternativas muy variadas en la literatura, cada una de ellas con su justificación respetiva. Anmala et. al (2000) han utilizado como predictores: precipitación mensual, temperatura y caudales promedios anteriores.

Un punto a destacar en esta parte, fue la decisión de utilizar como variable predictora, una variable climática. En este sentido, el trabajo de Jaime y Menéndez (2003), ha sido utilizado como referencial en ese contexto, ya que relacionaron caudales medios mensuales del río Paraná en la sección del tramo Paraná-Santa Fe, con la serie mensual de anomalías de temperatura de la superficie del Mar (TSM) en la región El Niño 3. Habiendo concluido, que el tiempo de retardo entre las anomalías de TSM y las de caudal medio mensual es de entre 3 y 5 meses, y que para las grandes crecidas, provocadas por el fenómeno de El Niño, existe una alta correlación entre el volumen de exceso y el índice IOS.

Otros autores como Cárdenas y Gil (2000), han utilizado como predictores, varios índices climáticos, como ser: las anomalías de temperatura de la superficie del mar en diferentes regiones, índices de ocurrencia del ENOS, Oscilación Pacífico-Caribe, Actividad solar, Oscilación cuasibienal, Anomalías de presión en Cajigal en meses anteriores. Con relación a los índices climáticos utilizados en el estudio, han concluido que los mismos sirven de espacio predictor que permiten la construcción de modelos de pronósticos físico-estadístico de caudal, y que han presentado correlaciones muy buenas, del orden de 0,90.

En el trabajo de Dolling y Varas (2001), han utilizado como predictoras, las siguientes variables climáticas: el índice IOS, temperatura mensual, humedad relativa promedio, horas de sol efectivas, viento promedio mensual, lluvia mensual, profundidad máxima de nieve, número de días soleados y caudales de tres meses anteriores. Concluyeron que el uso del indicador climático ha mejorado los resultados.

Otro trabajo que ha propuesto el uso de variables climáticas, ha sido el de Poveda et al. (2002), habiendo sido evaluado el uso de variables macroclimáticas como predictoras, entre ellas, la Temperatura de la Superficie del Mar, para la predicción de caudales medios mensuales de 6 ríos importantes para la generación

de energía eléctrica en Colombia. Concluyeron que la utilización de dichas variables favorece a las predicciones de caudales.

Luego de haber evaluado a los posibles predictores, se ha procedido a determinar, el tipo de preprocesamiento de datos a ser usado. Según García-Bartual (2005), los *inputs* deben ser objeto de un preprocesamiento numérico para permitir entrenamientos más eficaces. Revisando otras bibliografía al respecto, se ha encontrado en el trabajo de Dolling y Varas (2001), en el que los *inputs* utilizados fueron escalados en el rango $\pm 0,7$. En la tesis doctoral de Ochoa (2002), los datos de entradas, fueron sometidos a una normalización, tipificación y escalamiento, presentando en forma bien detallada cada uno de dichos procesos, los cuales han servido de referencia en este TFM.

Continuando con la evaluación de artículos de referencia, y pasando a la búsqueda de información acerca del tipo y arquitectura de una RNA, y cuál sería la más adecuada para predecir caudales mensuales. En este punto, se puede decir que se ha encontrado amplia información y bien variada al respecto.

Para iniciar con esta parte del análisis, y a modo de justificar el uso de una sola capa oculta o intermedia, Funahashi (1989), demuestra que una RNA *feedforward* (alimentada hacia adelante), con tres capas, una capa de entrada, una capa oculta y una de salida, es capaz de representar cualquier función multivariada continua y delimitada.

En esta parte cabe destacar que varios trabajos han presentado como recomendación para determinar una arquitectura de RNA, el llamado proceso de *prueba y error*, y lo que ha servido para que en este TFM sea seleccionado también ese proceso.

Los siguientes artículos a ser presentados, han sido seleccionados debido a que de los mismos han aportado varios temas como ejemplos, como ser: el objetivo y el tipo de la RNA, la arquitectura, el entrenamiento, el software utilizado, entre otros, por lo que una descripción más detallada de cada uno de ellos, ha sido considerada pertinente.

Anmala et al. (2000), han utilizado para predecir caudales mensuales de tres ríos dentro de los Estados Unidos, RNA y debido a que no existe reglas al respecto de cómo diseñar las RNA, proponen la exploración de varias RNA con distintas arquitecturas, en todas utilizan RNA feedforward, con tres capas, variando el número de nodos de la capa oculta, iniciando con 5 para luego aumentar la cantidad

Nilsson et al. (2006), evaluaron el uso de RNA, modelos conceptuales y una combinación de ambos, para predicciones mensuales de caudales, en dos cuencas de Noruega. Una red MLP feedforward fue utilizada en este estudio, con tres capas, la capa oculta con neuronas ocultas variando entre 5 a 15 y una capa de salida con una neurona. La función de activación utilizada en las neuronas de la capa oculta fue la tangente hiperbólica. El software usado fue el *MATLAB* y el algoritmo de entrenamiento fue el backpropagation con gradiente descendente. Como *inputs* iniciales fueron utilizadas precipitación y temperatura. El modelo de mejor resultado fue obtenido con la combinación de ambos modelos, con un $R^2=0,86$.

Ochoa (2002), elaboró una metodología para generar series sintéticas y como resultado, se dedujo un modelo estocástico multivariado no-lineal, basado en RNA del tipo Perceptron multicapa, con tres capas, variando las neuronas en la capa oculta. Los resultados obtenidos muestran que el nuevo modelo es más general, más robusto y de mayor memoria hidrológica que los métodos tradicionales, y constituye una nueva alternativa de alto rendimiento dentro del campo de la generación sintética de series temporales.

Poveda et al. (2002), evaluaron el uso de una RNA del tipo MLP con una capa oculta y como algoritmo de entrenamiento el backpropagation. Concluyeron que la utilización de dichas variables favorece a las predicciones de caudales, ya que no se requieren predicciones de las variables predictoras para efectuar predicciones de dichos caudales.

Prada-Sarmiento y Obregón-Neira (2009), analizaron el uso de las RNA para las predicciones de caudales mensuales en la cuenca superior del río Bogotá en Colombia, en un total de 19 subcuencas. La RNA desarrollada fue una MLP, como *input* solo tuvo a los caudales mensuales anteriores, y como *output* el caudal del mes siguiente. Fueron desarrolladas 8 RNA, para aplicarlas a las 19 subcuencas, se

utilizó el *MATLAB*, teniendo como resultados valores de $R^2 = 0,50$ aprox. en la verificación. También, han evaluado la relación entre los pesos de las mejores 3 RNA, con las características físicas de las subcuencas, a través de un análisis multivariado. Estos últimos han demostrado un mejor rendimiento en comparación con los primeros, llegando a valores de $R^2 = 0,72$.

Pujol (2009), desarrolló tres tipos de modelos para realizar predicciones de caudales diarios y horarios en dos secciones del río Paraná en la Argentina. Los modelos utilizados fueron: una RNA MLP, un modelo auto-regresivo de media móvil del tipo ARMAX y por último, una RNA auto-organizativa SOM. Para este trabajo se desarrolló una aplicación de software, basada en la caja de herramientas de RNA del *MATLAB*. Concluyó que el mejor modelo para realizar la predicción de caudales en este caso es la red SOM.

Wilby et al. (2003), han utilizado tres RNA del tipo MLP, entrenadas con el algoritmo de backpropagation, con una sola capa oculta con tres y seis neuronas ocultas, con la función logística en sus neuronas ocultas. Concluyeron que principalmente, con las redes de tres neuronas ocultas, se sugiere una conexión con al caudal base, la escorrentía directa y la humedad del suelo.

A modo final, se destaca de nuevo la gran versatilidad con la que se dispone para iniciar una modelación hidrológica, luego de haber consultado los libros y artículos presentados en este capítulo, en los que como recomendación casi consensuada hasta el momento, no existe algo fijo o ya preestablecido, para trabajar con este tipo de modelo.

En el siguiente capítulo, se presenta la metodología utilizada en este TFM, luego de haber hecho la revisión a cada uno de los artículos presentados.

5. Metodología

5.1. Antecedentes

La metodología propuesta por Dawson y Wilby (2001), en la cual se propone un protocolo para implementar modelos lluvia-caudal con RNA es:

- Adquisición de datos.
- Selección de la variable a predecir.
- Preprocesamiento de datos (*etapa 1*).
 - Limpieza de datos.
 - Identificación de predictores y variable a predecir.
- Selección del tipo de RNA.
 - Tipo de red.
 - Algoritmo de entrenamiento.
- Preprocesamiento de datos (*etapa 2*).
 - Estandarización de datos.
 - Selección de los sets de datos.
- Entrenamiento de las redes seleccionadas.
 - Arquitectura de la red.
 - Entrenamiento.
- Evaluación.

5.2. Metodología propuesta

Para este TFM, se ha utilizado una adaptación de la propuesta de Dawson y Wilby (2001), la cual se describe a continuación.

1. *Sondeo previo*: consistió en una exploración previa en la OPSH, en cuanto a la disponibilidad de datos, tanto de caudales como de registros de precipitaciones, así como de los datos macroclimáticos disponibles en la web de la NOAA, presentada más adelante.

2. *Variable a predecir*: el interés de la OPSH, radicó en realizar predicciones de caudales mensuales de ríos de su cuenca incremental, por lo que se definió como variable a predecir, el caudal del mes siguiente, $Q(t+1)$.

En el siguiente gráfico, de la figura 23, se muestra un esquema de lo que se pretende predecir, el caudal promedio mensual $Q(t+1)$, del río Amambái, en la Estación Florida, correspondiente al mes siguiente, el mes $(t+1)$, a partir de los datos observados hasta el mes actual mes (t) .

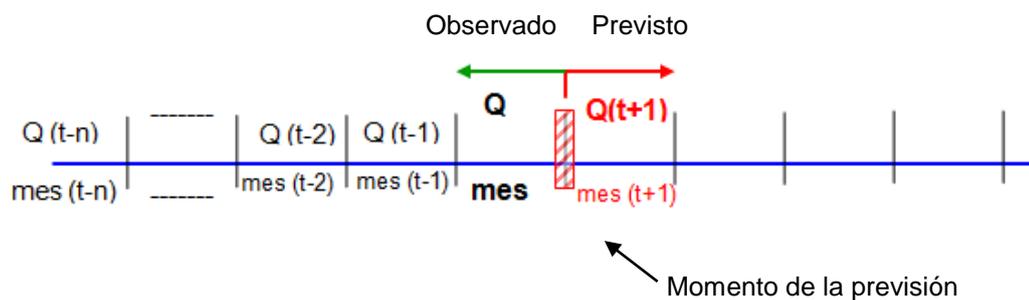


Figura 23 Esquema del momento de la previsión de caudales.

Estas predicciones, ya serían posibles realizarlas desde la última semana del mes (t) , o sea, del mes actual, ya que en la misma semana, ya se contaría con una estimación bastante aproximada de los predictores.

3. *Predictores de la variable a predecir*: se ha definido utilizar como predictores a: caudales promedios mensuales de los meses anteriores, precipitaciones medias en la cuenca y en forma experimental, variables macroclimáticas (explicado en 5.5.3). Jaime y Menéndez (2003), Cárdenas y Gill (2000), Poveda et al. (2002), han utilizado como predictores de caudales en sus respectivos estudios, diferentes variables macroclimáticas, como fue descrito en el Capítulo 4 de este TFM.

4. *Adquisición de datos*:

- Los datos de precipitación y caudales, utilizados en este estudio fueron obtenidos de la propia base de datos de la OPSH, el Gerenciador de Datos Hidrológicos (GDH), siendo los de precipitación, entregados como precipitaciones medias de la cuenca (PMC) en intervalo diario, transformados luego a escala mensual para su utilización en este TFM. Los datos de caudales pertenecen a la

Estación Florida, la cual registra en forma horaria los niveles, por lo que fueron, primero, promediados en forma diaria, y posteriormente en forma mensual.

- Los datos de las variables macroclimáticas fueron obtenidos de la página web del *Earth System Research Laboratory (ESRL)* del *National Oceanic & Atmospheric Administration (NOAA)*, cuya dirección web para descarga es la siguiente:

<http://www.esrl.noaa.gov/psd/data/climateindices/list/>

5. *Preprocesamiento de datos*: antes de presentar a la red los datos de entrada, ya previamente seleccionados, se debe realizar un pre-procesamiento a la serie de datos, diversos autores recomiendan al respecto, García-Bartual (2005), Ochoa (2002), Pujol (2009). Fue adoptado el procedimiento de Ochoa (2002), el cual está constituido básicamente por tres etapas bien definidas: Normalización, Tipificación y Escalamiento.

- Normalización: es el procedimiento para que la serie de datos adquiera distribuciones de probabilidad normal, (coeficiente de asimetría = 0) ya que de esta forma la red *capta* más rápidamente los patrones que se le presentan. Ochoa (2002), ha tomado la ecuación transformadora, ecuación (7), y le ha introducido un pequeño cambio en el coeficiente C original, convirtiéndolo en C_T dando así un carácter más variable a dicho parámetro en función al mes que se está analizando, y emplear un valor constante para cada uno de los meses. Por lo tanto se debe buscar un valor de C_T , tal que el coeficiente de asimetría de la nueva serie, sea lo más próximo a cero. Esto se logró gracias a la ayuda del comando *Solver* del Excel.

$$X_{VT} = \log(Q_{VT} + C_T \cdot \overline{Q_T}) \quad (7)$$

donde:

X_{VT}es la serie normalizada, correspondiente al mes T del año v .

Q_{VT}serie en su escala original, correspondiente al mes T del año v .

$\overline{Q_T}$es la media de los valores del mes T .

C_Tparámetro a ser calibrado para cada mes T .

- Tipificación: es la remoción de las tendencias y periodicidades de las series, y puede realizarse restando a cada uno de sus valores X_{VT} de la serie nueva normalizada, las respectivas medias mensuales \bar{X}_T y dividiendo esas diferencias por las desviaciones típicas mensuales normalizadas S_{XT} . Ecuación (8).

$$Y_{VT} = \frac{X_{VT} - \bar{X}_T}{S_{XT}} \quad (8)$$

donde:

Y_{VT}es la serie tipificada correspondiente al mes T del año v .

X_{VT}es la serie normalizada correspondiente al mes T del año v .

\bar{X}_Tes el promedio de la serie normalizada correspondiente al mes T .

S_{XT}es la desviación típica de la serie normalizada.

- Escalamiento: su propósito es transformar las series temporales así como están procesadas hasta este punto, o sea, la serie tipificada (Y_{VT}), en una nueva serie que adopte un rango similar al de la función de activación a ser usada en los nodos de la RNA, según Dawson et al. (2002), debido a que de esta forma se obtiene una mayor eficiencia en el entrenamiento y utilización de la red, y con el fin de que la red pueda predecir caudales por fuera del rango de valores empleados en el entrenamiento. Para ello, se puede usar la ecuación (9):

$$Z_T = \frac{(L_S - L_i)Y_{VT} + (L_i \cdot M_Z - L_S \cdot m_Z)}{M_Z - m_Z} \quad (9)$$

donde:

Z_Tes la serie escalada.

M_Zes el máximo valor de la serie temporal Y_{VT} (serie tipificada).

m_Zes el mínimo valor de la serie temporal Y_{VT} (serie tipificada).

L_Slímite superior del intervalo a adoptar para escalar.

L_ilímite inferior del intervalo a adoptar para escalar.

El intervalo $[Li, Ls]$ se selecciona de tal manera que sea menor o igual al rango de las funciones de activación; así, si este es por ejemplo $[0, 1]$, se puede adoptar un intervalo de $[0,2; 0,8]$. Ochoa (2002). Para este TFM, fue adoptado el intervalo correspondiente a $[-0,9; 0,9]$.

6. Selección del tipo y arquitectura de red: para la definición del tipo de RNA a ser utilizado, Dawson y Wilby (2001), recomiendan que para problemas de predicciones las *MultiLayer Perceptron* (MLP), y las *Radial Basis Function* (RBF), son puntos de partidas apropiados para tal efecto, y en el cual de nuevo, dichos investigadores, enfocan en que se inicien los estudios con las redes MLP.

Otros autores, Hsu et al. (1995), Dawson et al. (2002), Wilby et al. (2003), Pujol (2009), Ochoa (2002), han utilizados RNA del tipo MLP en sus respectivos estudios de modelación lluvia-caudal.

En este TFM, se ha optado, por utilizar una red MLP *feedforward* (alimentada hacia adelante) con nodos totalmente conectados, con tres capas; una capa de entrada, una capa oculta o intermedia y una capa de salida. Como Función de Activación, tanto en las neuronas de la capa oculta, como en la neurona de la capa de salida, ha sido utilizada la Tangente Hiperbólica, que produce una salida comprendida en el intervalo $[-1, 1]$.

Por último, en el gráfico de la figura 24, se muestra en forma esquemática, el tipo y arquitectura de RNA adoptada finalmente para este TFM.

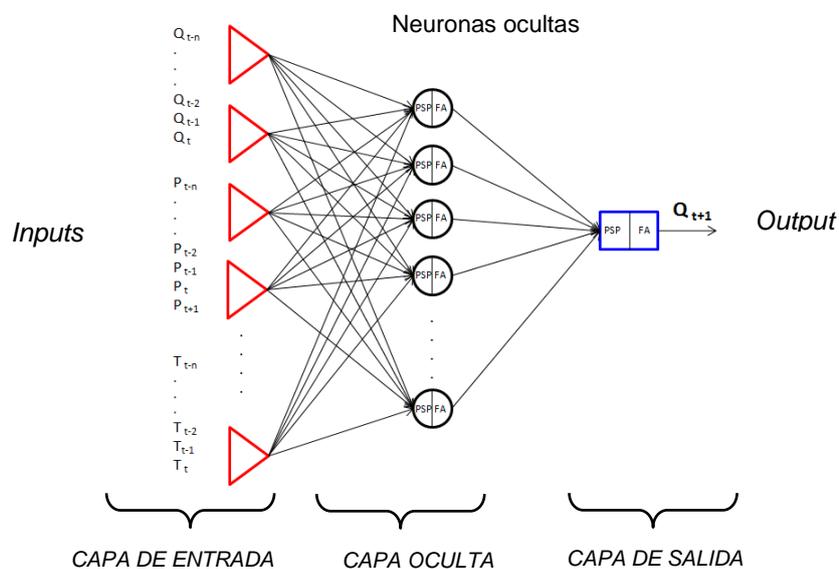


Figura 24 Tipo y arquitectura de red adoptada.

La selección de los datos de entradas o *inputs*, ha sido realizada en función a los resultados de las correlaciones, cuyos resultados se presentan en el Capítulo 6. y han servido para establecer hasta que tiempo atrás es considerado para ser usado como *input*.

Para definir las redes a ser entrenadas, se han tomado en cuenta dos componentes para definir finalmente las combinaciones de redes a ser entrenadas: uno fijo y otro variable. Los componentes fijos se han mantenido sin modificaciones a lo largo de todo el entrenamiento, mientras que los variables, han sido los que se han modificado a lo largo del entrenamiento. En la Tabla N° 2, se presenta un resumen de los mismos.

Tabla 2 Componentes fijos y variables de las RNA a ser entrenadas.

COMPONENTES DE LAS RNA A SER ENTRENADAS	
FIJOS	VARIABLES
Tipo de red (FFBP)	<i>Inputs</i> (con relación a la antecedencia):
Capas: 1 de entrada, 1 oculta y 1 de salida	Caudales: $Q(t-n) \dots n=0, 1, 2$
Función de Activación	Precipitación: $P(t-n) \dots n=0, 1, 2$
Algoritmo de entrenamiento	Temperatura: $T(t-n) \dots n=1, 2, 3, 4$
División de datos para entrenamiento (%)	Número de neuronas en la capa oculta

El último paso, en lo que a selección de *inputs* se refiere, ha sido establecer las RNA propiamente dichas a ser entrenadas, optando por elaborar 6 redes a ser entrenadas. Más detalles de las mismas en el Capítulo 6 de esta TFM.

7. Entrenamiento: el entrenamiento o calibración, fue realizado con la herramienta de redes neuronales artificiales del *MATLAB* 7.11.0, autores como Nilsson (2005), Larentis (2007) y Prada-Sarmiento (2009), entre otros, han utilizado el toolbox del *MATLAB*. Figura 25.

La serie total de datos, para iniciar el entrenamiento fue dividida de la siguiente forma: 60% entrenamiento, 20% validación cruzada y 20% test.

El primer paso es la carga de los datos de entrada (*inputs*) y de los datos de salida (*targets*) figura 25, luego de la creación de la red propiamente dicha, definiendo en la misma, el nombre de la red, el tipo de red, el número de capas, función de activación, algoritmo de entrenamiento, función objetivo, etc.

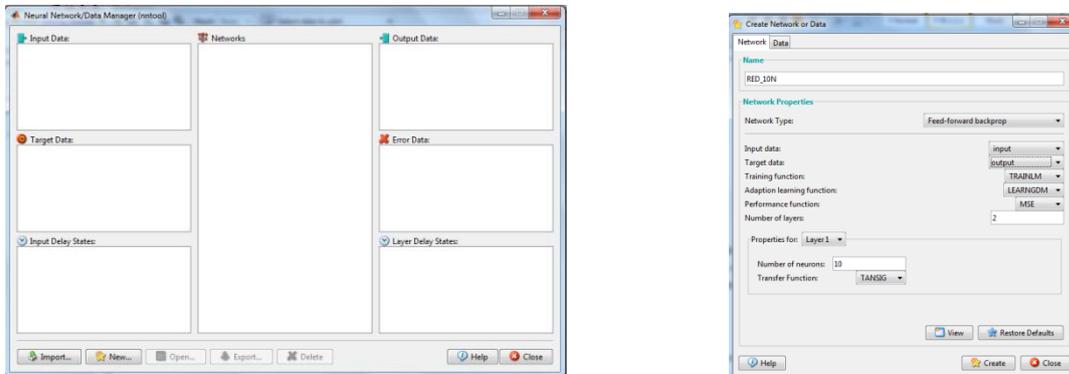


Figura 25 Ventana de carga de datos y de creación de la RNA en el MATLAB.

Hecho esto, se abre la red recientemente creada, la cual finalmente va a ser la interfase usuario principal del entrenamiento, como se ve en la figura 26.

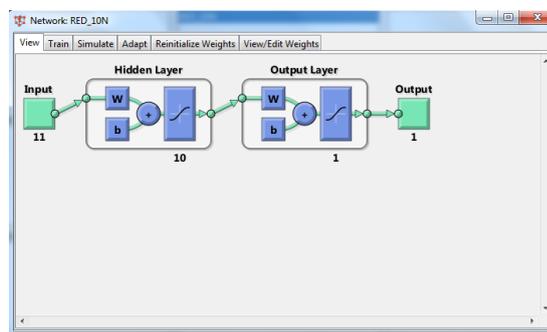


Figura 26 Ventana de vista de la RNA diseñada

Luego, se entra en la pestaña *Train*, asumiendo los pesos iniciales propuestos por el software si es que así se desea, y se acciona el botón *Train Network* para iniciar el entrenamiento, figura 27.

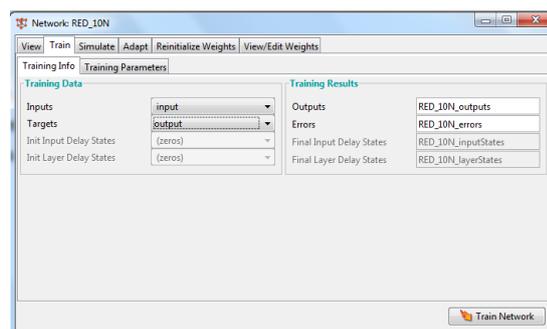


Figura 27 Ventana de entrenamiento de la RNA

Realizado el primer entrenamiento, se visualizan los resultados del mismo, tanto de ajustes de regresión, como de parada por validación, como se ve en la Figura 28.

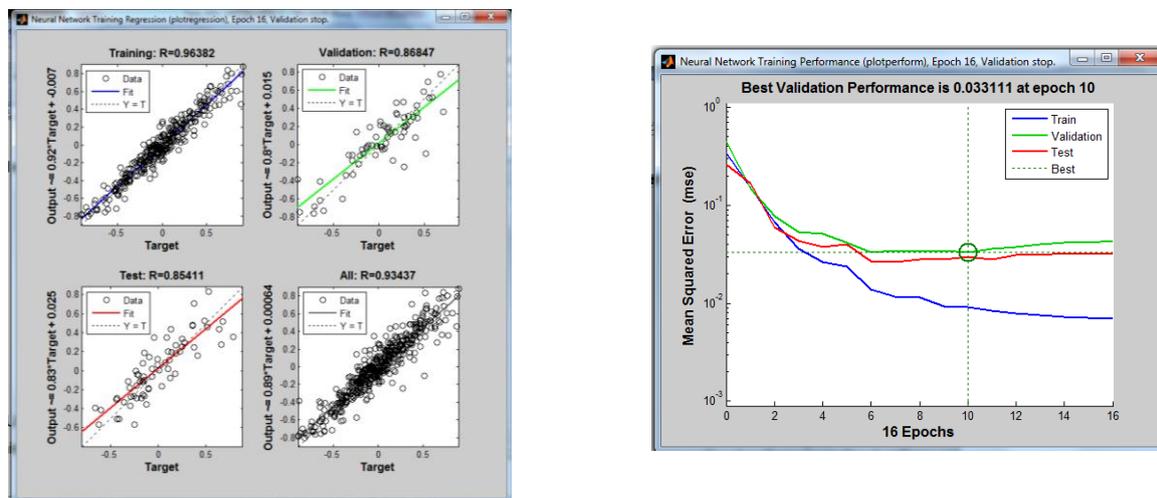


Figura 28 Ventanas de visualización de resultados de simulaciones.

Una vez analizados los resultados obtenidos en el primer entrenamiento, y si los mismos no son satisfactorios, se procede a ir a la pestaña de Reinicialización de Pesos, en donde, se deben reinicializar los pesos (los cuales son calculados por el software en forma aleatoria), para de esa forma poder tener otro punto de partida para un nuevo entrenamiento. Se realiza este procedimiento, de forma iterativa, (prueba y error, alrededor de 30 iteraciones) hasta que los resultados sean los satisfactorios, momento en el cual se guardan los valores de los pesos calculados, los cuales serán utilizados en futuras simulaciones sin variar los mismos.

Otro punto importante es que para cada red diseñada, se ha variado la cantidad de neuronas en la capa oculta de 5 en 5, o sea, en la primera simulación, la red consta de 5 neuronas, la siguiente 10, y así sucesivamente hasta llegar a las 25 neuronas ocultas en la capa oculta. Dawson et al. (2002).

8. Análisis de resultados: para el análisis de los resultados obtenidos, se han diseñado gráficos comparativos de series Observadas y Calculadas, y se han calculado índices de ajustes o de bondad, e índices de medición de errores.

Como índice de bondad han sido utilizados el Coeficiente de Correlación r^2 (CC), ecuación (10) y el Coeficiente de Eficiencia de *Nash* y *Sutcliffe* (CE) ecuación (11) mostrados a continuación:

$$r^2 = \left[\frac{\sum_{i=1}^n (Q_{i\text{ obs}} - \bar{Q}_{\text{obs}}) (Q_{i\text{ sim}} - \bar{Q}_{\text{sim}})}{\sqrt{\sum_{i=1}^n (Q_{i\text{ obs}} - \bar{Q}_{\text{obs}})^2 \sum_{i=1}^n (Q_{i\text{ sim}} - \bar{Q}_{\text{sim}})^2}} \right]^2 \quad (10)$$

$$CE = 1 - \frac{\sum_{i=1}^n (Q_{i\text{ obs}} - Q_{i\text{ sim}})^2}{\sum_{i=1}^n (Q_{i\text{ obs}} - \bar{Q}_{\text{obs}})^2} \quad (11)$$

Como índices de error han sido utilizados la Raíz Cuadrada del Error Cuadrático Medio (RMSE), ecuación (12) y el Error Medio Absoluto (MAE) ecuación (13) mostrados a continuación:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Q_{i\text{ obs}} - Q_{i\text{ sim}})^2}{n}} \quad (12)$$

$$MAE = \frac{\sum_{i=1}^n |Q_{i\text{ obs}} - Q_{i\text{ sim}}|}{n} \quad (13)$$

donde:

$Q_{i\text{ obs}}$es la serie de caudales observados

\bar{Q}_{obs}es el promedio de la serie de caudales observados.

$Q_{i\text{ sim}}$es la serie de caudales simulados.

\bar{Q}_{sim}es el promedio de la serie de caudales simulados.

6. Estudio de caso

6.1. Río Amambaí

6.1.1. Descripción de la cuenca

La cuenca del Río Amambaí, figura 29, se encuentra en el estado brasileño de Mato Grosso do Sul, al sur-oeste del Brasil, forma parte de la cuenca incremental de la CHI, tiene un área total de aproximadamente 10.390 km², esto es aproximadamente el 7% de la cuenca incremental. Rivarola (2008).

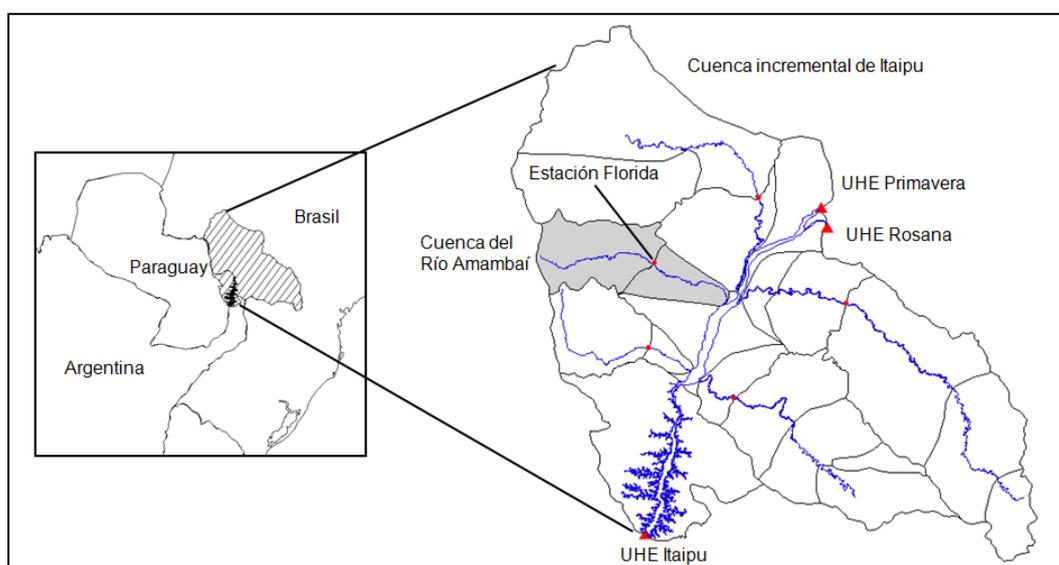


Figura 29 Ubicación geográfica, cuenca del río Amambaí en la cuenca incremental de Itaipu.

La topografía del estado de Mato Grosso (margen derecha del río Paraná), se caracteriza por ser poco ondulada y por tener poco uso del suelo, con lo cual la cobertura vegetal es mayor en relación a los del estado de. Estas características mencionadas, hacen que se tengan crecidas con máximos no muy elevados y los caudales de estiaje sin embargo son mayores por unidad de área. Rivarola (1994)

El río Amambaí, tiene una longitud de aproximadamente 300 Km. en su cauce principal, nace en las Cordilleras del Amambay, cerca de la frontera con el Paraguay, y es afluente por la margen derecha al río Paraná. Tiene un tiempo de viaje hasta la CH Itaipu de aproximadamente 2 días.

6.2. Estación Florida.

La estación Florida, figura 30, pertenece al Sistema de Telemetría Hidrometeorológico (STH) de la Itaipu Binacional. Es del tipo pluviométrico y fluviométrico, en la figura 29 se puede ver su ubicación en la cuenca.

Su área de cobertura es del 68% (7090 km²) de la cuenca total del río Amambaí, y el restante 32%, hacia la confluencia con el río Paraná, es un área no controlada o no monitoreada en términos hidrológicos. Rivarola (2008).



Figura 30 Estación hidrometeorológica Florida y lance de reglas limnimétricas.

Los datos de altura del río, en dicha sección, son registrados por intermedio de un sensor de nivel, ubicado dentro del cuerpo de agua en el río, que registra la presión hidrostática, la cual es calibrada con la utilización de la regla limnimétrica, figura 30. De igual forma, los datos de las precipitaciones, son registrados en un pluviómetro, el cual registra en forma automática la precipitación horaria acumulada, la cual luego es consistida en forma horaria y almacenada en formato diario.

Estos datos son transmitidos finalmente vía satélite, para así llegar a una estación central en la CHI, y desde ahí a una de las base de datos de la OPSH, el Gerenciador de Datos Hidrometeorológicos (GDH).

Los datos de niveles, son transformados en cotas y luego en caudales con la utilización de una curva del tipo *cota-caudal*, la cual fue enteramente elaborada por el sector de Hidrología de campo de la OPSH con mediciones hechas en diferentes periodos, estiaje, crecidas y normales.

6.3. Análisis de datos

El análisis de los datos a ser utilizados en un cualquier modelación es una de las partes más importantes de la misma, ya que de la calidad de ellos y del pre-tratamiento a que son sometidos tendrá un alto impacto en la calidad de los resultados. En los siguientes capítulos serán presentados los resultados obtenidos de los análisis de correlaciones realizados entre las variables.

6.3.1. Correlaciones entre variables

El cálculo de los CC entre las diferentes variables y el caudal a predecir, ha sido realizado con el objeto de ser el soporte al momento de seleccionar los *inputs* para las RNA. Los cálculos han sido realizados con las series tipificadas (las cuales han sido detalladas en 5.2) y se han calculado los CC entre la variable a predecir $Q(t+1)$ y cada uno de los predictores.

En el gráfico de la figura 31, se presentan los resultados de los valores de los coeficientes de correlación entre caudal promedio mensual del río Amambái, del mes siguiente $Q(t+1)$, con los caudales antecedentes $Q(t-n)$.

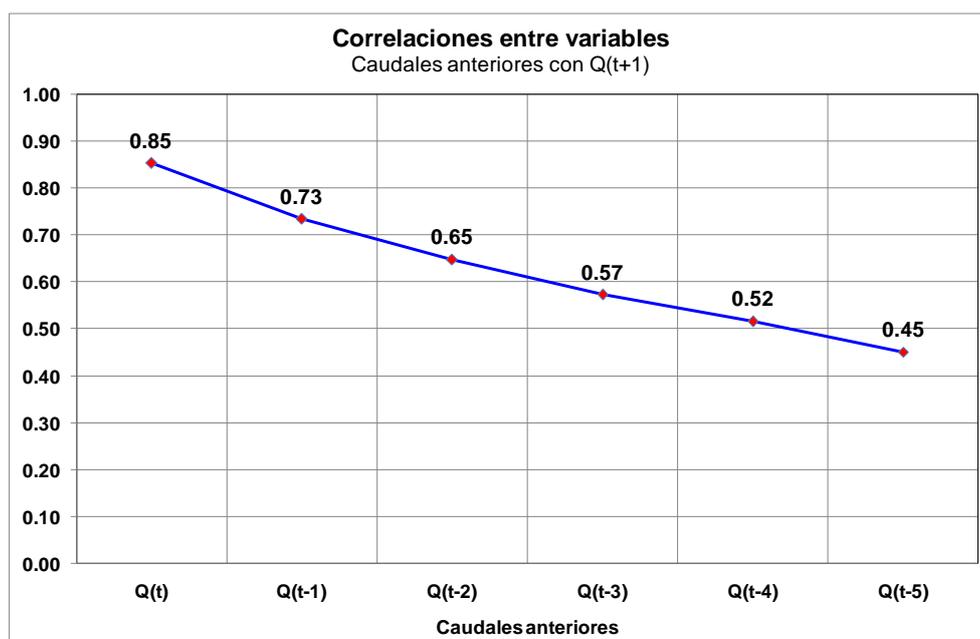


Figura 31 Correlaciones entre caudal a predecir y caudales anteriores.

Se puede observar una alta correlación de 0,85 entre el caudal a predecir $Q(t+1)$ y el caudal del mes inmediatamente anterior $Q(t)$ y luego valores que van en descenso para los demás meses anteriores.

En el gráfico de la figura 32, se presentan los resultados de los valores de los coeficientes de correlación entre caudal promedio mensual del río Amambaí, del mes siguiente $Q(t+1)$, con los valores de precipitaciones antecedentes $P(t-n)$.

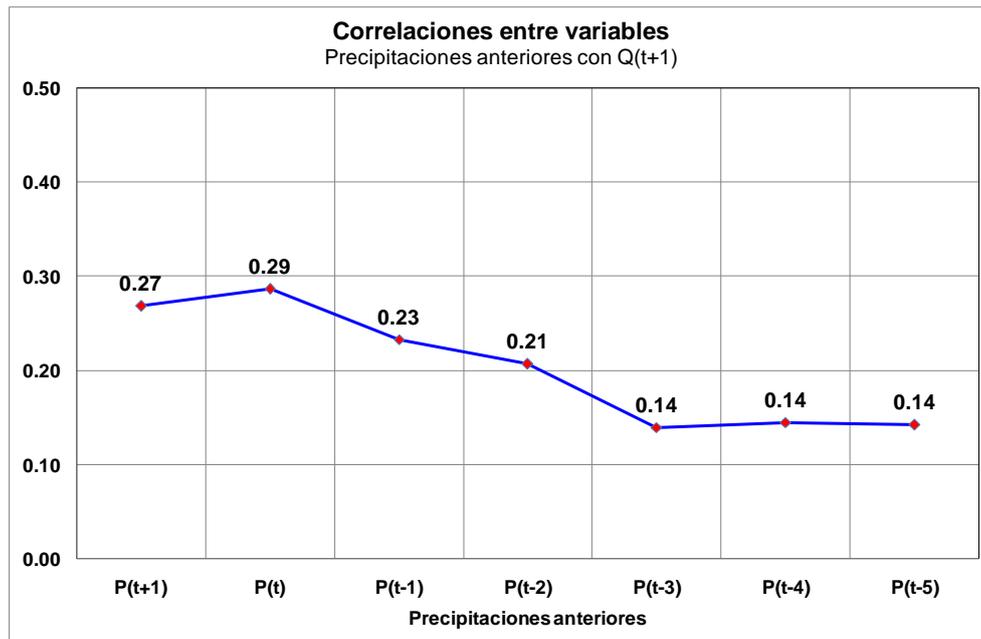


Figura 32 Correlaciones entre caudal a predecir y las precipitaciones.

Se puede observar que la correlación mayor entre el caudal a predecir $Q(t+1)$ y la precipitación del mes inmediatamente anterior $P(t)$ es levemente mayor a las demás de los meses anteriores, así como también es mayor a la del mes siguiente $P(t+1)$.

En el gráfico de la figura 33, se presentan los resultados de los valores de los coeficientes de correlación entre caudal promedio mensual del río Amambaí, del mes siguiente $Q(t+1)$, con los valores de TSM antecedentes $Q(t-n)$.

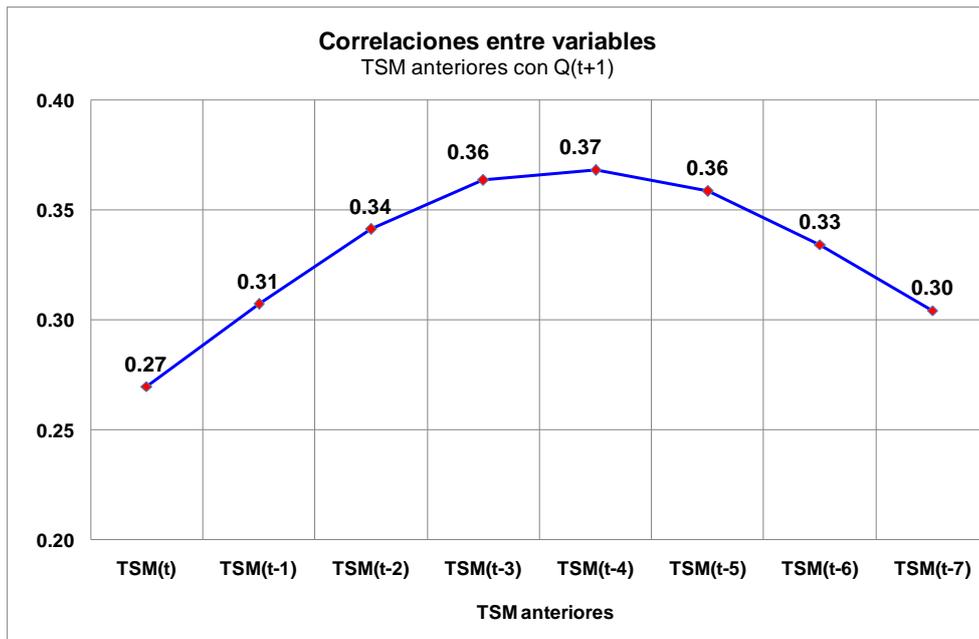


Figura 33 Correlaciones entre caudal a predecir y las temperaturas de la sup. del mar.

Se puede observar que la correlación mayor entre el caudal a predecir $Q(t+1)$ y el valor de TSM se presenta cuatro meses atrás con relación al mes actual de la predicción.

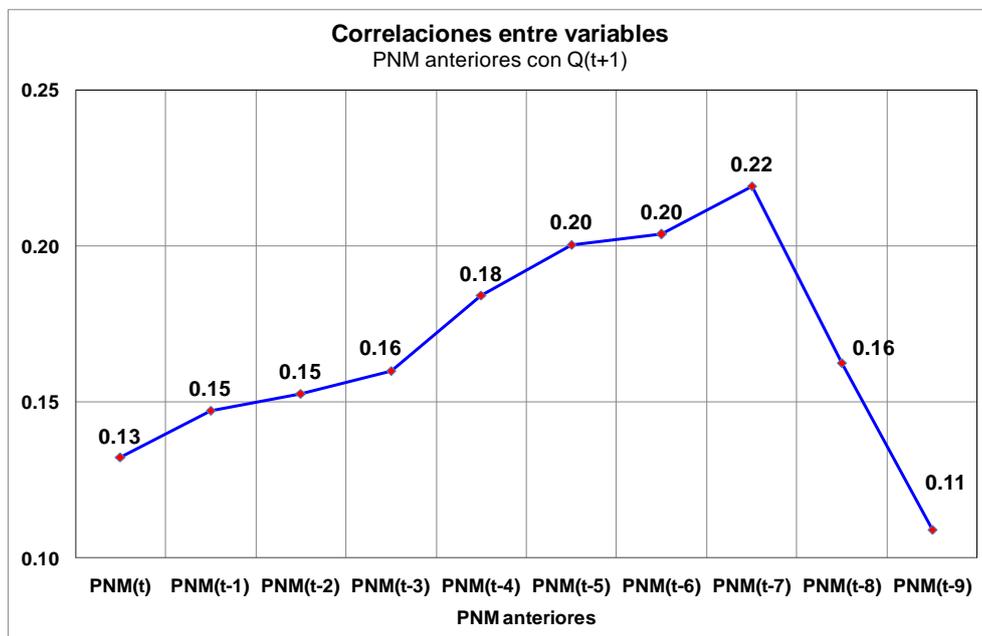


Figura 34 Correlaciones entre caudal a predecir y la presión a nivel del mar.

En el gráfico de la figura 34, se presentan los resultados de los valores de los coeficientes de correlación entre caudal promedio mensual del río Amambáí, del mes siguiente $Q(t+1)$, con los valores de PNM antecedentes $Q(t-n)$.

Se puede observar que la correlación mayor entre el caudal a predecir $Q(t+1)$ y el valor de PNM se presenta siete meses atrás con relación al mes actual de la previsión.

En el gráfico de la figura 35, se presentan los resultados de los valores de los coeficientes de correlación entre caudal promedio mensual del río Amambáí, del mes siguiente $Q(t+1)$, con los valores de PNM antecedentes $Q(t-n)$.

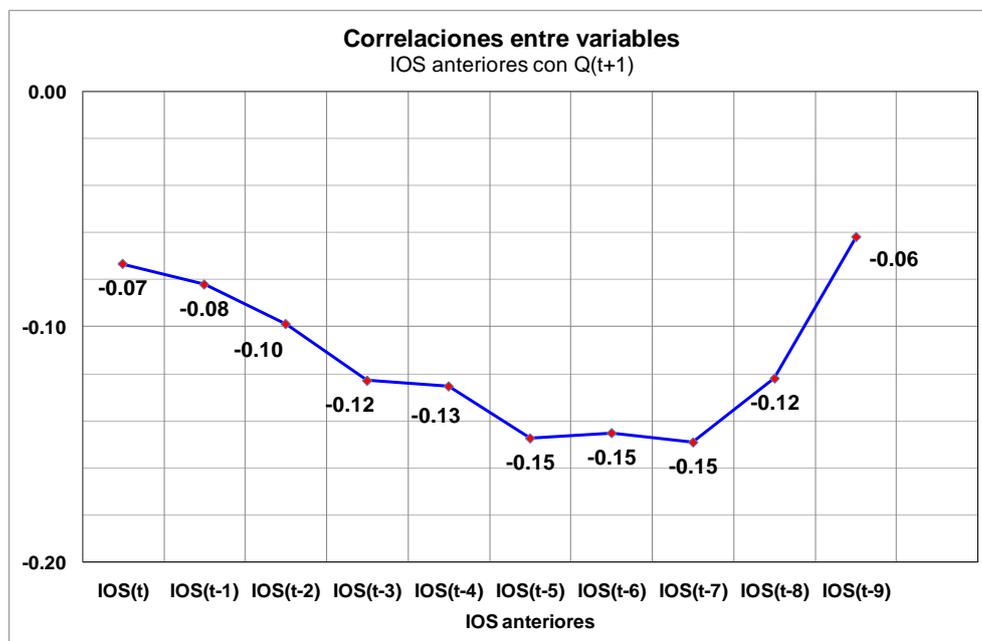


Figura 35 Correlaciones entre caudal a predecir y el índice de oscilación del sur.

Se puede observar que la correlación entre ambas variables, el caudal a predecir $Q(t+1)$ y el valor de IOS, es negativa, es baja y se presenta cinco meses atrás con relación al mes actual de la previsión.

Por último, a modo de resumen de los resultados obtenidos en esta etapa de cálculo de los CC, se presentan en la Tabla 3.

Tabla 3 Resumen de las correlaciones entre caudal a predecir y las diferentes variables.

Tiempo de antecedencia	Correlaciones de Q ($t+1$) con variables de entrada				
	Caudal	Precipitación	IOS	PNM	TSM
t	0.85	0.29	-0.07	0.13	0.27
t-1	0.73	0.23	-0.08	0.15	0.31
t-2	0.65	0.21	-0.10	0.15	0.34
t-3	0.57	0.14	-0.12	0.16	0.36
t-4	0.52	0.14	-0.13	0.18	0.37
t-5	0.45	0.14	-0.15	0.20	0.36

6.4. Selección de Inputs

Como se expresó en 6.2.1, los análisis de correlaciones fueron realizados con el objetivo de servir de soporte para la toma de decisión en cuanto a la selección de *inputs* y a la determinación de las RNA propiamente dichas.

Con relación a la selección de *inputs*, en base a los resultados, de las correlaciones con el caudal a predecir, presentados en la tabla 6.1, se ha decidido seleccionar como *inputs*, para los modelos de RNA a ser diseñados: al caudal, a la precipitación y a la TSM., ya que los mismos han sido los que han presentado las mayores correlaciones, descartando de esta forma a la PNM y al IOS.

Una vez seleccionados los *inputs*, se debe ahora seleccionar el paso de tiempo de antecedencia a ser utilizado para cada *input* seleccionado, para lo cual se han tomado en cuenta de nuevo los resultados de las correlaciones, de la tabla 3, para cada uno de ellos.

En el caso del Caudal, se consideraron los tiempos de antecedencia t , $t-1$ y $t-2$, para la precipitación t , $t-1$ y $t-2$ y para la TSM se han considerado $t-1$, $t-2$, $t-3$ y $t-4$.

A partir de esto, se han definido finalmente 6 (seis) RNA a ser entrenadas, combinando los *inputs*, con los tiempos de antecedencia. En la tabla 4 se presentan las redes seleccionadas.

Tabla 4 Resumen de las 6 RNA con sus respectivos *inputs* a ser diseñadas.

RED NEURONAL N°					
1	2	3	4	5	6
Q (t)	Q (t)	Q (t)	Q (t)	Q (t)	Q (t)
Q (t-1)	Q (t-1)	Q (t-1)	Q (t-1)	Q (t-1)	Q (t-1)
Q (t-2)	Q (t-2)	Q (t-2)	Q (t-2)	Q (t-2)	Q (t-2)
P (t)	P (t)	P (t)	P (t)	P (t)	P (t)
P (t-1)	P (t-1)	P (t-1)	P (t-1)	P (t-1)	P (t-1)
P (t-2)	P (t-2)	P (t-2)	P (t-2)	P (t-2)	P (t-2)
	P (t+1)	TSM (t-4)	P (t+1)	TSM (t-1)	P (t+1)
			TSM (t-4)	TSM (t-2)	TSM (t-1)
				TSM (t-3)	TSM (t-2)
				TSM (t-4)	TSM (t-3)
					TSM (t-4)

La red N° 1, es la que se puede considerar como patrón, ya que los mismos *inputs* se mantienen en las demás redes. La misma presenta como *inputs* a los caudales actuales y anteriores, y a la precipitación del mes y de los meses anteriores.

La red N° 2, a más de los *inputs* contemplados en la red N° 1, se le ha adicionado el término de precipitación del mes siguiente representado por $P(t+1)$. La red N° 3, es la red N° 1 con la adición del término de TSM del 4° mes anterior al presente, representado por $TSM(t-4)$. La red N° 4, es la red N° 1, con la adición de la precipitación del mes siguiente $P(t+1)$ y del término de TSM del 4° mes anterior al

presente la $TSM(t-4)$. La red N° 5, es la red N° 1, solo con la adición de los 4 *inputs* correspondientes de la *TSM*, o sea, $TSM(t-1)$ al $TSM(t-4)$. Finalmente, la red N° 6, es la red N° 5, con la adición del término de precipitación del mes siguiente representado por $P(t+1)$.

7.Resultados y discusiones.

Primero, serán presentadas las comparaciones entre las RNA con un mismo *input*, y en el que se podrán comparar y analizar los resultados de índices como son el Coeficiente de Correlación (CC), el Coeficiente de Eficiencia de Nash & Sutcliffe (CE), la Raíz del Error Cuadrático Promedio (RMSE) y el Error Absoluto Promedio (MAE), en función de la variación del número de neuronas ocultas.

Luego, serán presentadas las comparaciones entre las RNA con diferentes *inputs*, para de esa forma poder tener seleccionada la de mejor desempeño y por ende, la de mejor representatividad y generalización del caudal promedio mensual de todo el trabajo.

RED NEURONAL N° 1

La Red N° 1, es la considerada como la red patrón en este TFM, debido a que los *inputs* de esta se mantienen en todas las demás redes. La figura N° 36, muestra los resultados de los índices de ajustes (CC y CE) y de errores (RMSE y MAE) de la Red N° 1, para los distintos números de neuronas ocultas utilizadas, que fueron 5, 10, 15, 20 y 25, tanto en los conjuntos de datos de entrenamiento y del test.

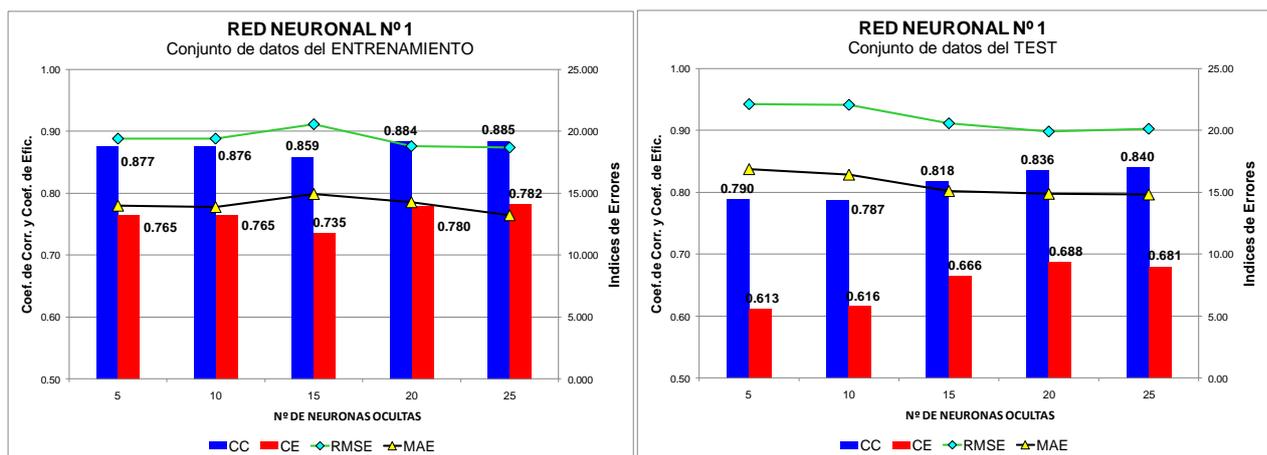


Figura 36 Índices de ajustes y errores. RN2

En el entrenamiento, todas las redes han resultado con un desempeño bastante similar, considerando la variación de la cantidad de neuronas ocultas. Para el test, las redes con 5, 10 y 15 han presentado valores similares, siendo las redes con 20 y 25 neuronas, las que han demostrado resultados similares, por lo que ante esta

situación, se selecciona a la de 20 neuronas ocultas como la de mejor desempeño, con un CC de 0.836 y un CE de 0.688.

En los gráficos de la figura 37, se presentan los resultados obtenidos en forma de caudales observados vs. caudales simulados, con la línea a 45° de simulación perfecta, de la Red N°1 con 20 neuronas ocultas, la cual ha sido seleccionada anteriormente como la de mejor desempeño. Se puede apreciar, en el conjunto de datos del Test, que para valores bajos se encuentran más concentrados los puntos, mientras que, para valores altos, se puede notar una cierta dispersión en dichos puntos, con relación a la línea de 45°.

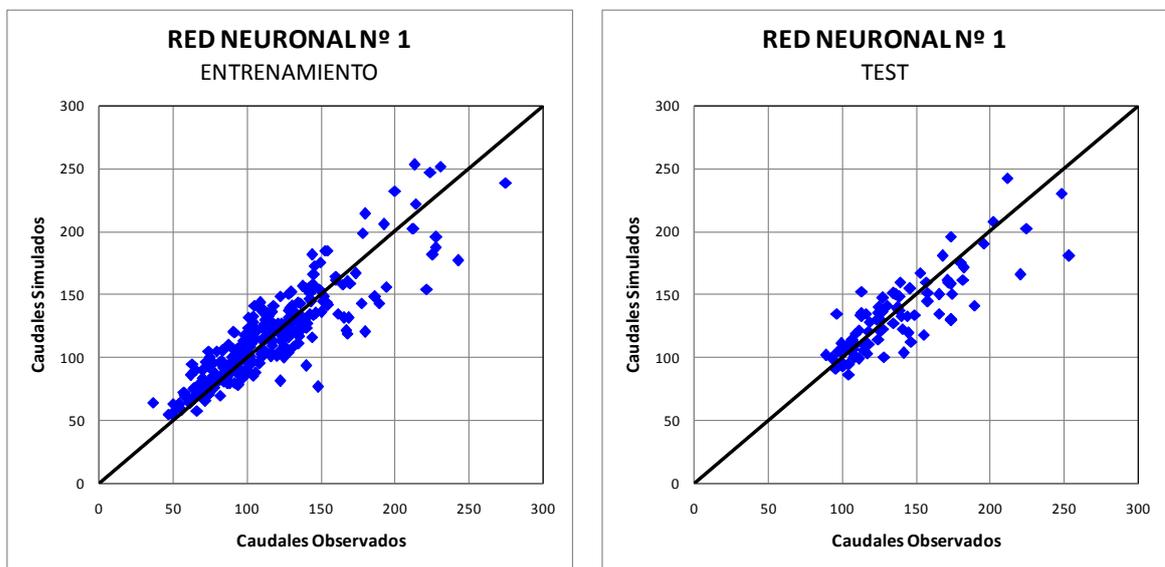


Figura 37 Caudales Observados vs. Simulados. RN1

En la figura 38, se muestran los hidrogramas de las series observadas y simuladas de la red con 20 neuronas ocultas, con todos los conjuntos de datos utilizados: los del entrenamiento, de la validación cruzada y del test.

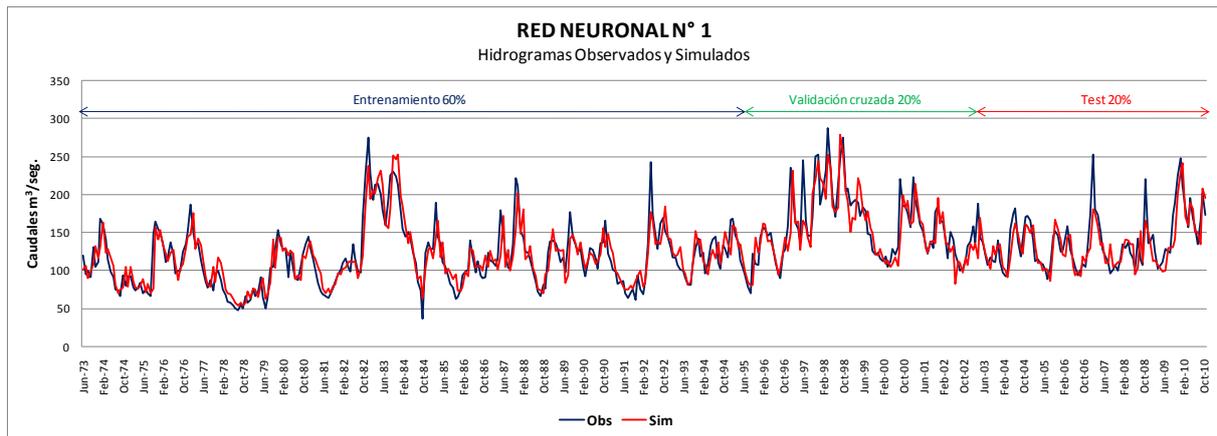


Figura 38 Hidrogramas Observados y Simulados. Serie completa. RN1

En la parte correspondiente al Test, de los tres picos que se presentan (Febrero 2007, Noviembre 2008 y Enero 2010), solo en uno de ellos (Enero 2010) se tuvo un buen ajuste, mientras que para valores menores a los 150 m³/seg, se presenta un cierto retraso o desfase en las predicciones, disminuyendo un tanto de esta forma la capacidad de generalizar de esta red, como se puede ver en la figura 39.

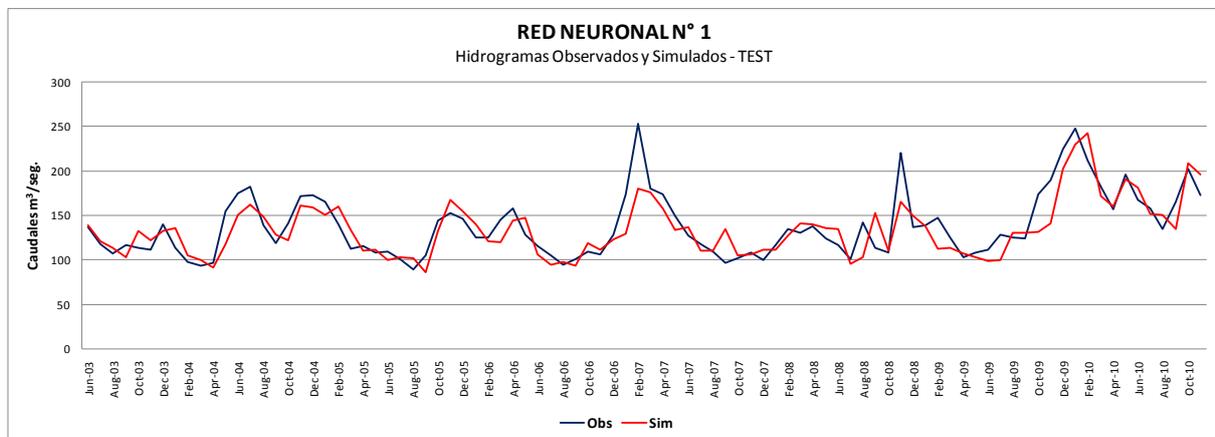


Figura 39 Hidrogramas Observados vs. Simulados. Serie del TEST. RN1

RED NEURONAL N° 2

La Red N° 2, es la red N° 1 con la adición del termino de precipitación del mes siguiente como nuevo *input*, el $P(t+1)$. La figura N° 40, muestra los resultados de los índices de ajustes (CC y CE) y de errores (RMSE y MAE) de la Red N° 2, para los distintos números de neuronas ocultas utilizadas, que fueron 5, 10, 15, 20 y 25, tanto en los conjuntos de datos de entrenamiento y del test.

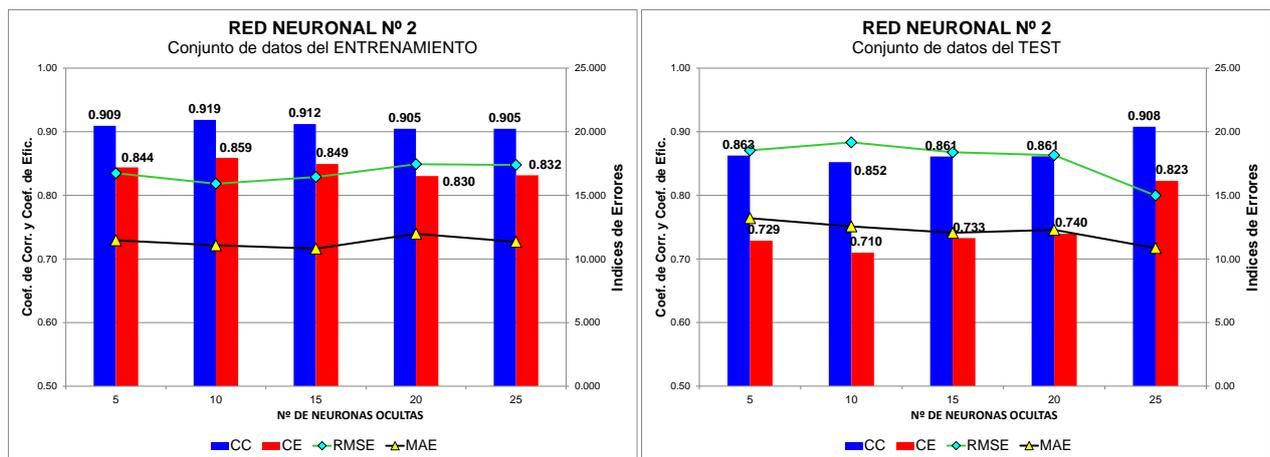


Figura 40 Índices de ajustes y errores. RN2

En el entrenamiento, todas las redes simuladas han resultado con un desempeño similar, con valores de promedio de CC de 0.9 y de CE de 0.840 en promedio. En el gráfico del test, se puede notar que el CC y el CE han resultado bastante similar para las redes con 5, 10, 15 y 20 neuronas ocultas, y destacándose para la red con 25 neuronas ocultas, la cual ha demostrado ser la de mejor desempeño, con un CC de 0.908 y un CE de 0.823, por lo que ha sido seleccionada como la mejor de la RN2.

En los gráficos de la figura 41, se presentan los resultados obtenidos en forma de caudales observados vs. caudales simulados, con la línea a 45° de simulación perfecta, de la Red N° 2 con 25 neuronas ocultas, la cual ha sido seleccionada anteriormente como la de mejor desempeño. Se puede apreciar, en el conjunto de datos del Test, que los valores tanto para caudales altos y bajos, se encuentran más próximos a la línea de 45°.

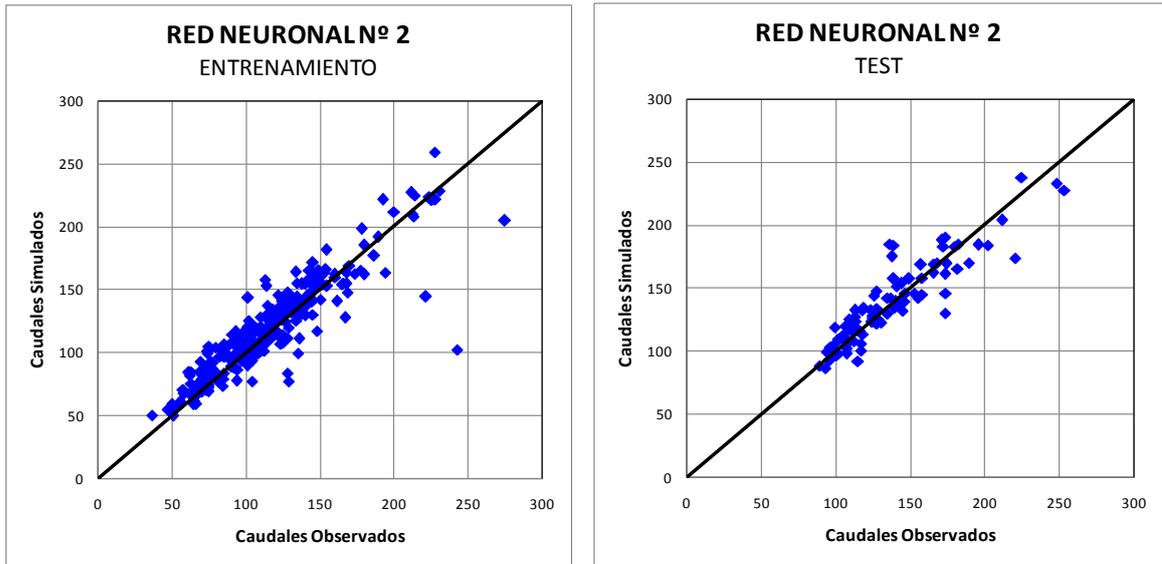


Figura 41 Caudales Observados vs. Simulados. RN2

En la figura 42, se muestran los hidrogramas de las series observadas y simuladas de la red con 25 neuronas ocultas, con todos los conjuntos de datos utilizados, los del entrenamiento, de la validación cruzada y del test.

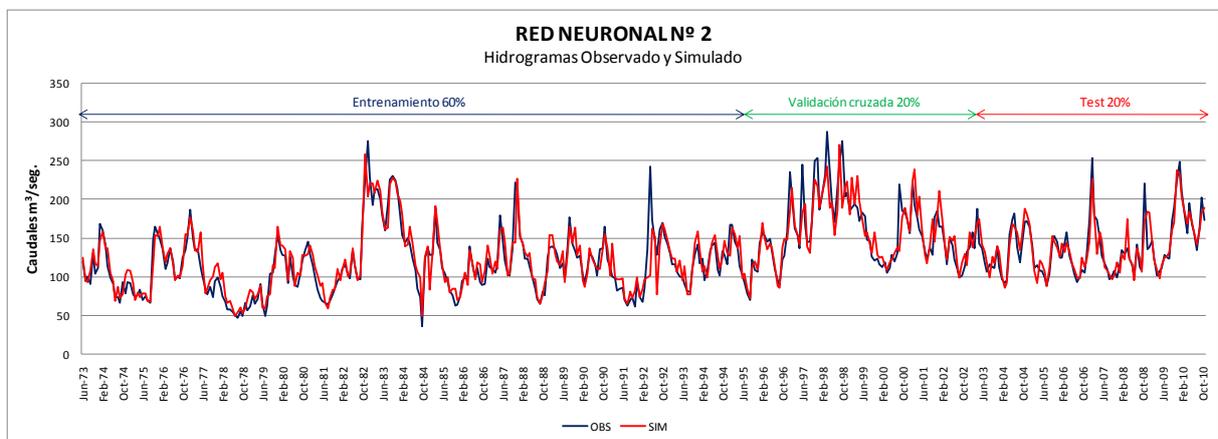


Figura 42 Hidrogramas Observados y Simulados. Serie completa. RN2

Con relación al Test, de los tres picos que se presentan (Febrero 2007, Noviembre 2008 y Enero 2010), en dos de ellos se tuvo buen ajuste, y para valores comprendidos en la faja de los 100 a los 150 m³/seg. se tuvo un ajuste satisfactorio, como se puede ver en la figura 43.

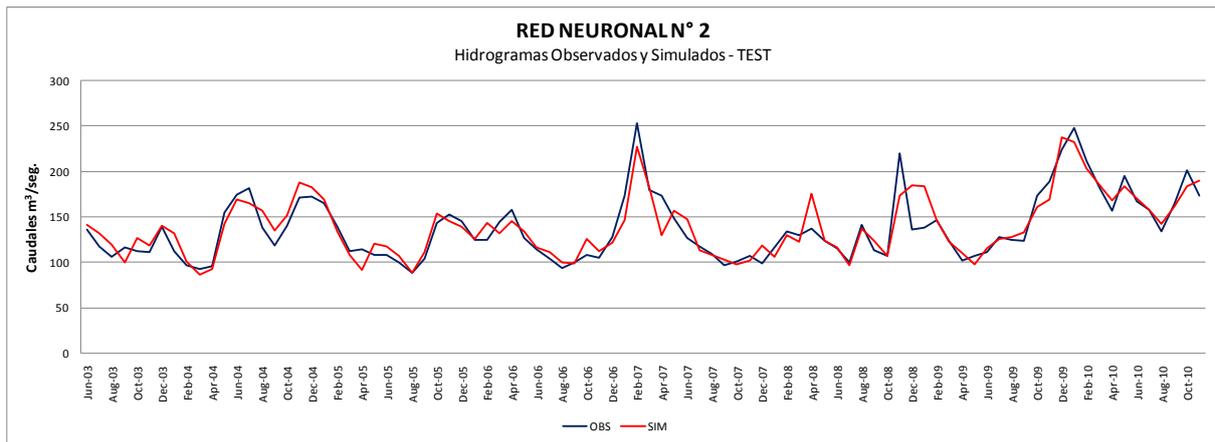


Figura 43 Hidrogramas Observados vs. Simulados. Serie del TEST. RN2

RED NEURONAL Nº 3

La Red Nº 3, es la red Nº 1 con la adición del término de la TSM de 4 meses atrás como nuevo *input*, el *TSM (t-4)*. La figura Nº 44, muestra los resultados de dicha Red, tanto en los conjuntos de datos de entrenamiento y del test, con los distintos números de neuronas ocultas utilizadas, que en este TFM fueron de 5, 10, 15, 20 y 25.

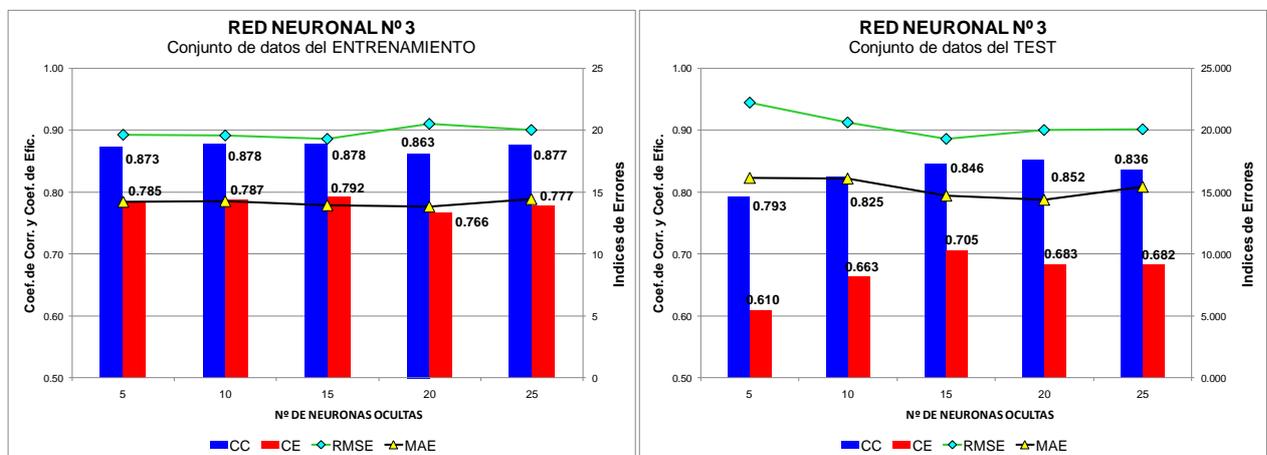


Figura 44 Índices de ajustes y errores. RN3

Del gráfico 44, en el entrenamiento, todas las redes simuladas han resultado con un desempeño similar, con valores de CC de 0.870 en promedio, y con valores de CE de 0.77 en promedio. En cuanto al test, la red con 15 neuronas ocultas, ha presentado los mejores resultados, superando a las redes de 5, 10, 20 y 25 neuronas ocultas, por lo que ante esta situación, se selecciona a la misma como la de mejor desempeño, con valores de CC de 0.846 y de CE de 0.705.

En los gráficos de la figura 45, se presentan los resultados obtenidos en forma de caudales observados vs. caudales simulados, con la línea a 45° de simulación perfecta, de la Red N° 3 con 15 neuronas ocultas, la cual ha sido seleccionada anteriormente como la de mejor desempeño.

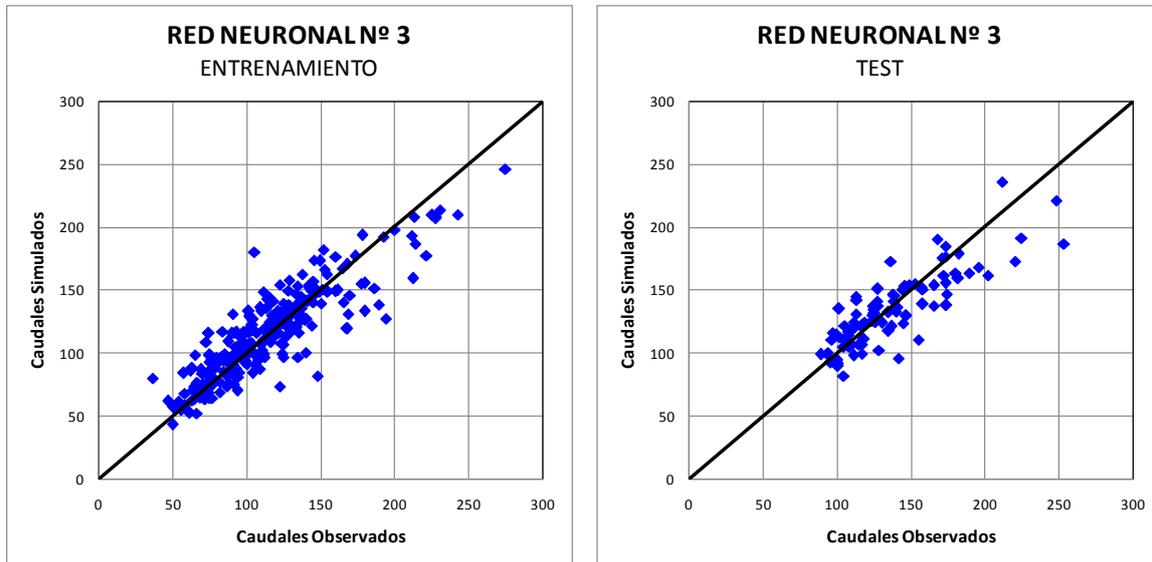


Figura 45 Caudales Observados vs. Simulados. RN3

De la figura 45, se puede apreciar, que en el conjunto de datos del Test, los puntos en general se encuentran distanciados con relación a la línea de 45°.

En la figura 46, se presentan los hidrogramas de las series observadas y simuladas de la red con 15 neuronas ocultas, con todos los conjuntos de datos utilizados; del entrenamiento, de la validación cruzada y del test.

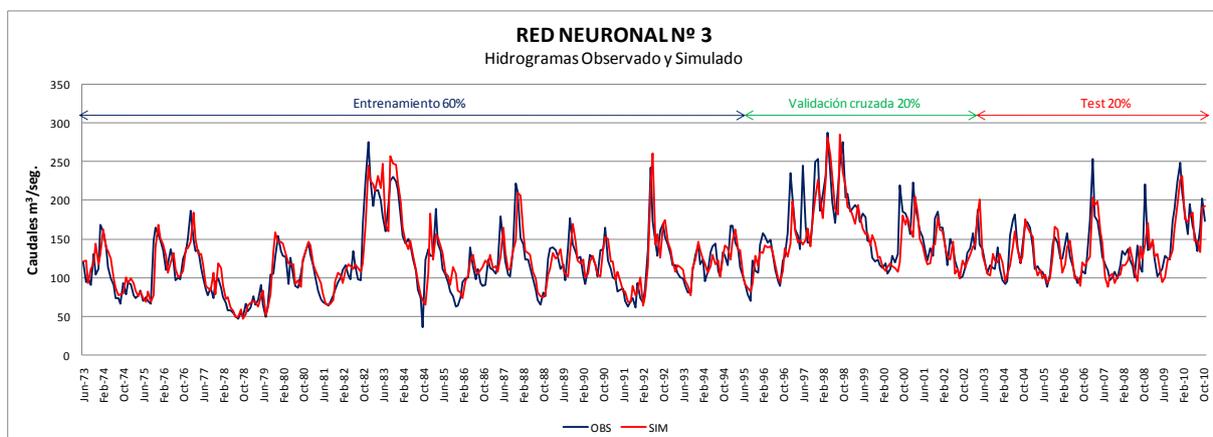


Figura 46 Hidrogramas Observados y Simulados. Serie completa. RN3

En la parte correspondiente al Test, de los tres picos que se presentan (Febrero 2007, Noviembre 2008 y Enero 2010), solo en uno de ellos, en Enero 2010, se tuvo un buen ajuste, mientras que para valores menores a los 150 m³/seg, se presenta un cierto retraso o desfasaje en las predicciones, disminuyendo un tanto de esta forma la capacidad de generalizar de esta red, como se puede ver en la figura 47.

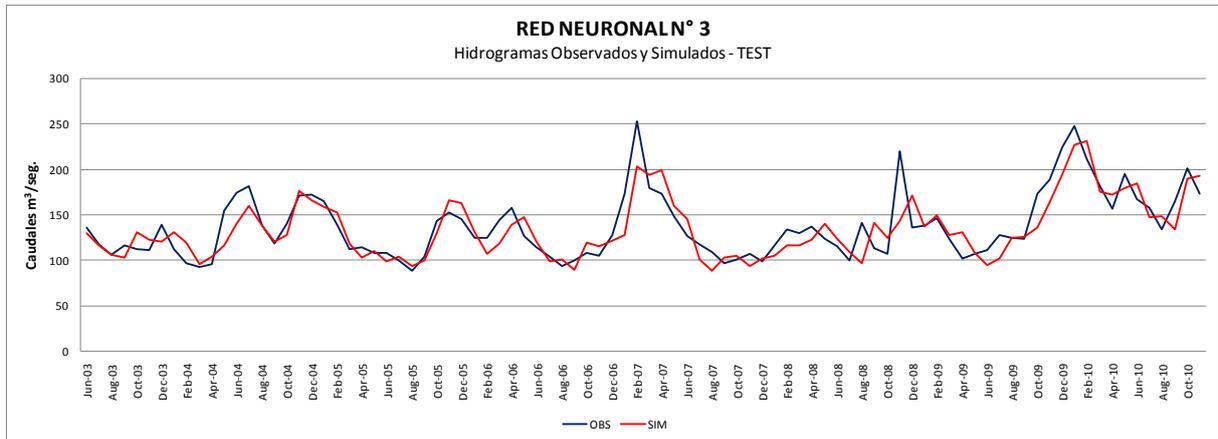


Figura 47 Hidrogramas Observados vs. Simulados. Serie del TEST. RN3

RED NEURONAL N° 4

La Red N° 4, es la red N° 1, con la adición de la precipitación del mes siguiente $P(t+1)$ y del término de TSM del 4º mes anterior al presente la $TSM(t-4)$. La figura 48, muestra los resultados de dicha Red, tanto en los conjuntos de datos de entrenamiento y del test, con los distintos números de neuronas ocultas utilizadas, que en este TFM fueron de 5, 10, 15, 20 y 25.

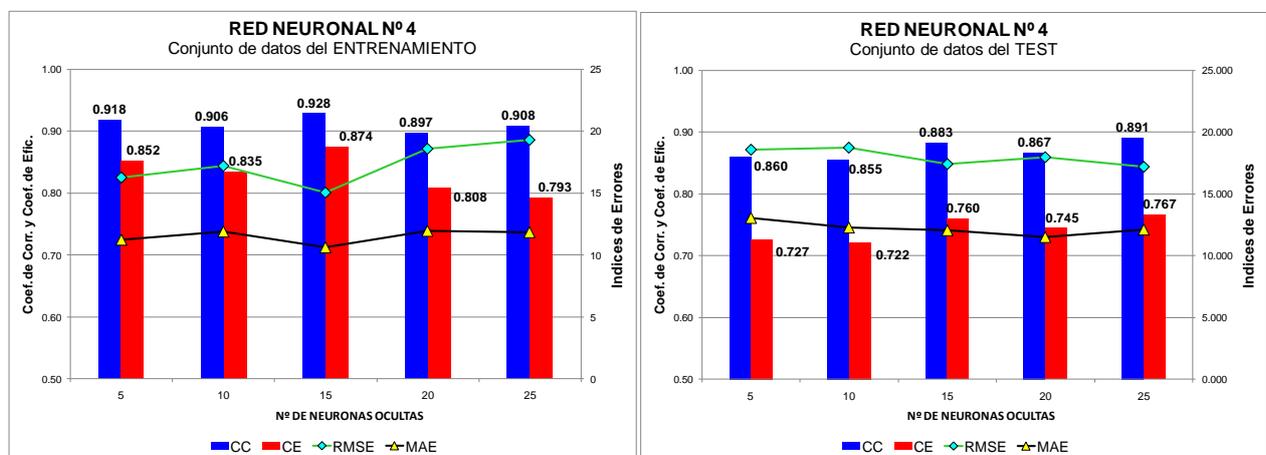


Figura 48 Índices de ajustes y errores. RN4

En el entrenamiento, todas las redes simuladas han resultado con un desempeño similar, con valores de CC de 0.90 en promedio, y con valores de CE entre 0.790 a 0.870. En el test, la red con 25 neuronas, ha demostrado mejor desempeño, levemente superior a la de 15 neuronas ocultas, por lo que ante esta situación, se selecciona a la de 25 neuronas ocultas como la de mejor desempeño, con un CC de 0.891 y un CE de 0.767.

En los gráficos de la figura 49, se presentan los resultados obtenidos en forma de caudales observados vs. caudales simulados, con la línea a 45° de simulación perfecta, de la Red N°4 con 25 neuronas ocultas, la cual ha sido seleccionada anteriormente como la de mejor desempeño.

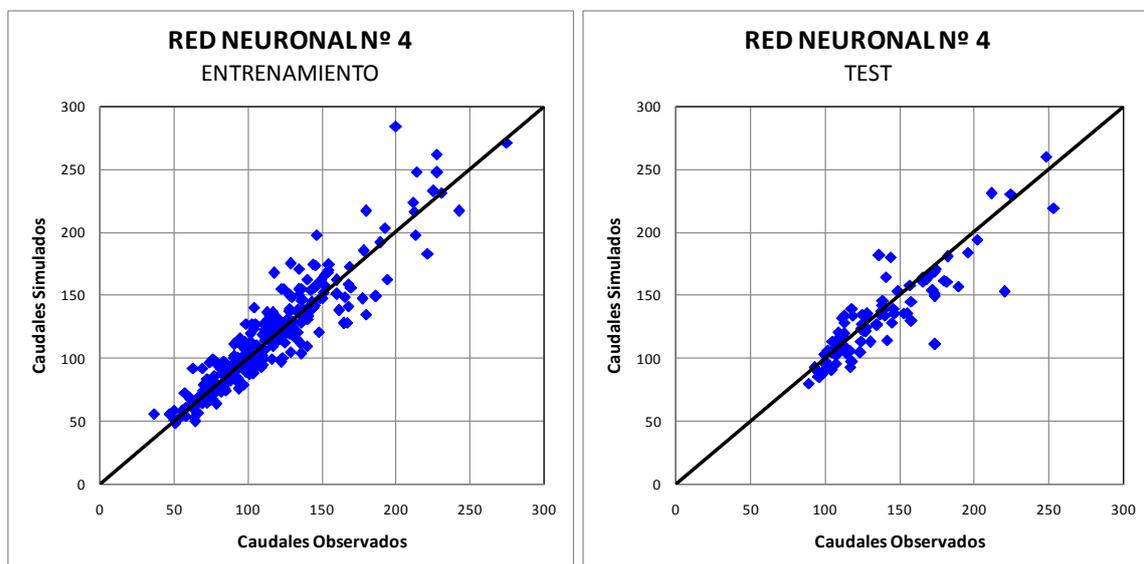


Figura 49 Caudales Observados vs. Simulados. RN4

Se puede apreciar, en el conjunto de datos del Test, que para valores bajos se encuentran más concentrados los puntos, mientras que, para valores medios, se puede notar una cierta dispersión en algunos puntos.

En la figura 50, se muestran los hidrogramas de las series observadas y simuladas de la red con 25 neuronas ocultas, con todos los conjuntos de datos utilizados, los del entrenamiento, de la validación cruzada y del test.

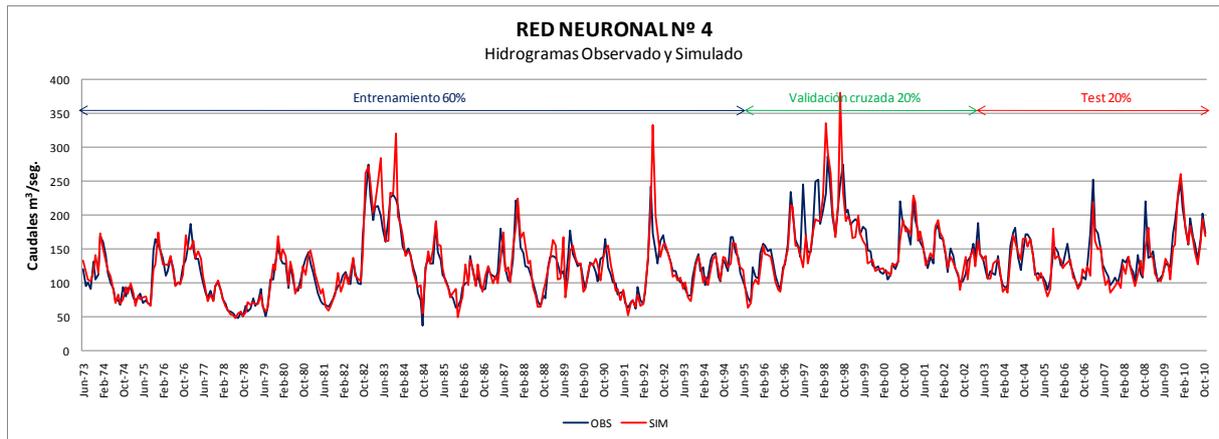


Figura 50 Hidrogramas Observados y Simulados. Serie completa. RN4

En la parte correspondiente al Test, de los tres picos que se presentan (Febrero 2007, Noviembre 2008 y Enero 2010), en dos de ellos se tuvo buen ajuste, y para valores menores a los 200 m³/seg. se tuvo también un buen ajuste, como se puede ver en la figura 51.

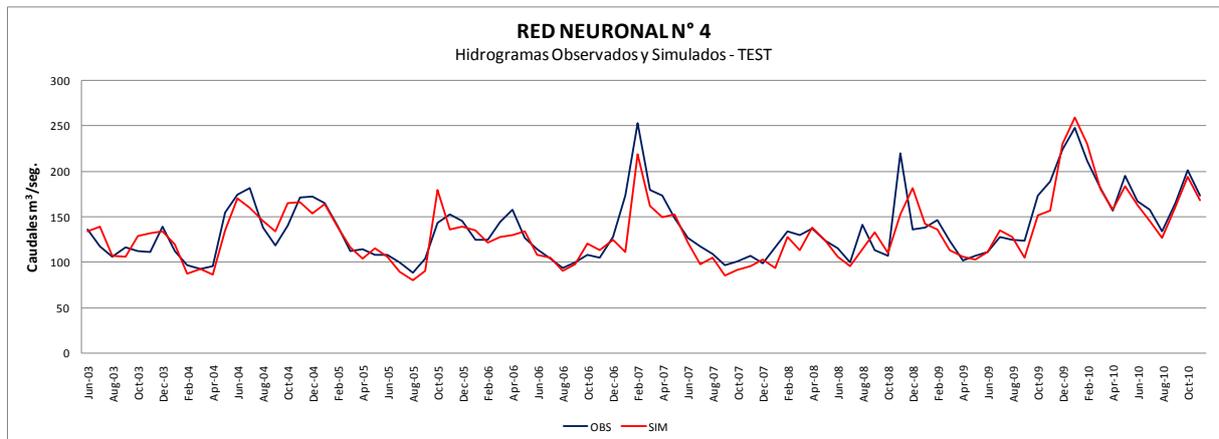


Figura 51 Hidrogramas Observados vs. Simulados. Serie del TEST. RN4

RED NEURONAL N° 5

La Red N° 5, es la red N° 1 con la adición de los valores de la TSM de los 4 meses anteriores. La figura N° 52, muestra los resultados de dicha Red, tanto en los conjuntos de datos de entrenamiento y del test, con los distintos números de neuronas ocultas utilizadas, que en este TFM fueron de 5, 10, 15, 20 y 25.

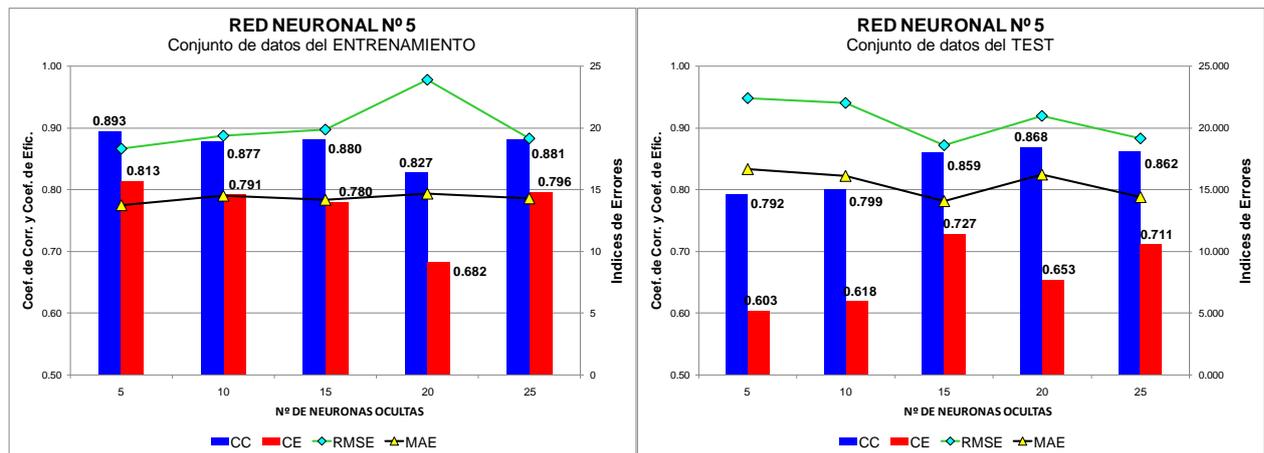


Figura 52 Índices de ajustes y errores. RN5

En el entrenamiento, todas las redes simuladas han resultado con un desempeño similar, con valores de CC de 0.88 en promedio, y con valores de CE de 0.79 y un valor más bajo de 0.682. Para el test, la red con 15 neuronas, ha demostrado resultados superiores en tres de los cuatro índices, solo el CC de la red de 20 neuronas ha superado al de 15 neuronas ocultas, por lo que ante esta situación, se selecciona a la de 15 neuronas ocultas, como la de mejor desempeño, con un CC de 0.859 y un CE de 0.727.

En los gráficos de la figura 53, se presentan los resultados obtenidos en forma de caudales observados vs. caudales simulados, con la línea a 45° de simulación perfecta, de la Red N°5 con 15 neuronas ocultas, la cual ha sido seleccionada anteriormente como la de mejor desempeño.

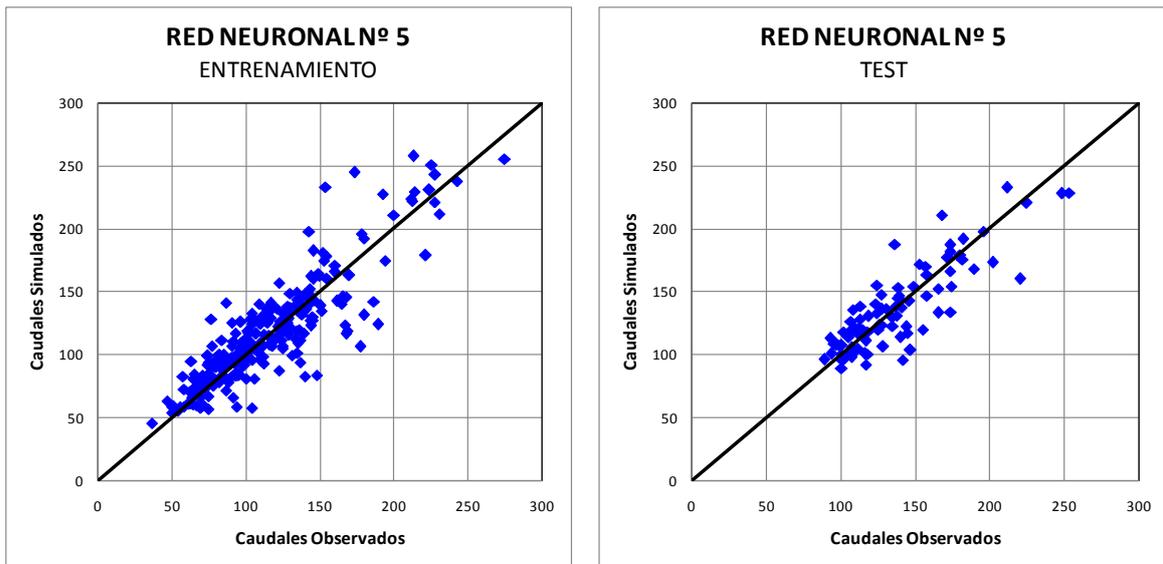


Figura 53 Caudales Observados vs. Simulados. RN5

Se puede apreciar en la figura 53, que en el conjunto de datos del Test, los valores en general, no están tan ajustados, ya que del mismo gráfico, se puede notar una cierta dispersión de los datos, con relación a la línea de 45°, de simulación perfecta.

En la figura 54, se muestran los hidrogramas de las series observadas y simuladas de la red con 15 neuronas ocultas, con todos los conjuntos de datos utilizados, los del entrenamiento, de la validación cruzada y del test.

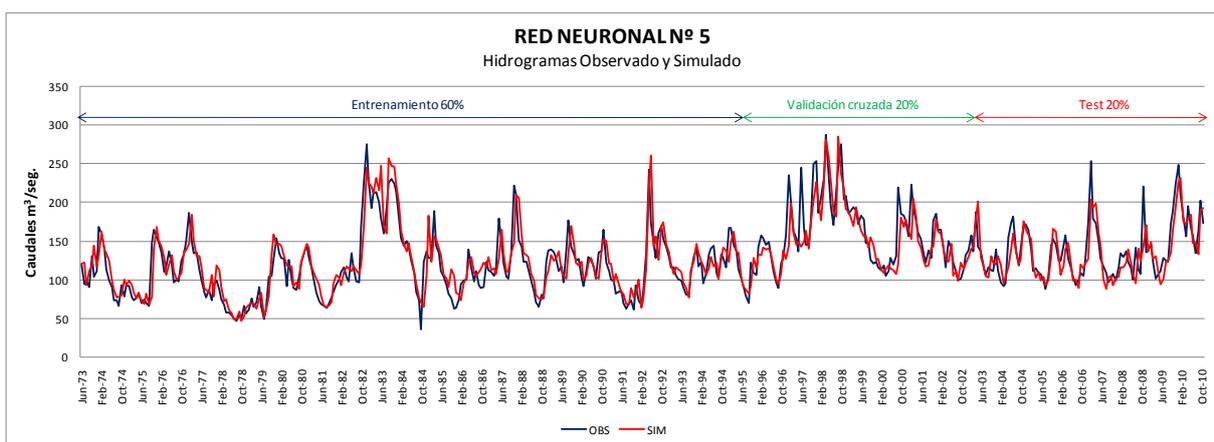


Figura 54 Hidrogramas Observados y Simulados. Serie completa. RN5

En la parte correspondiente al Test, de los tres picos que se presentan (Febrero 2007, Noviembre 2008 y Enero 2010), no se tuvo un buen ajuste en ninguno de ellos, y para valores menores a los 150 m³/seg., se presenta un cierto retraso o desfase en las predicciones, disminuyendo un tanto de esta forma la capacidad de generalizar de esta red como se puede ver en la figura 55.

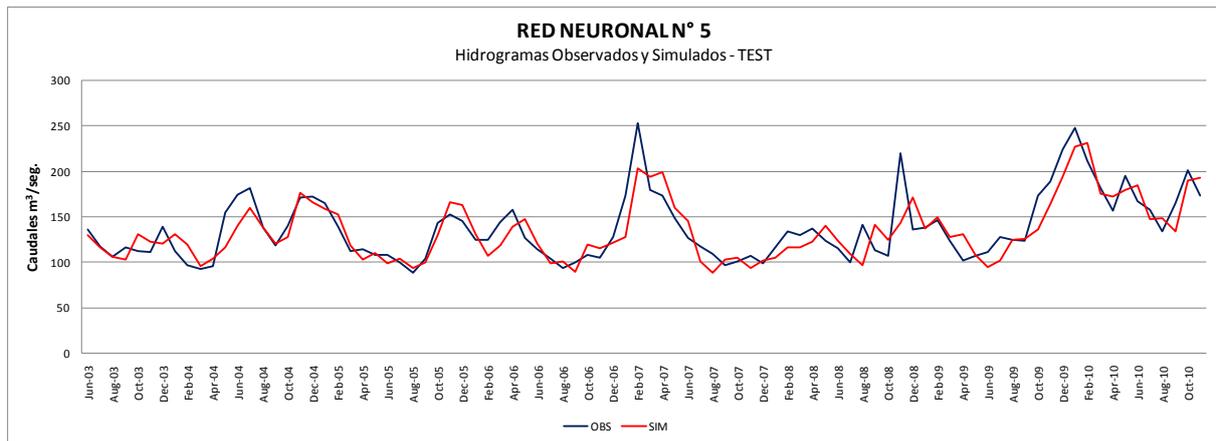


Figura 55 Hidrogramas Observados vs. Simulados. Serie del TEST. RN5

RED NEURONAL N° 6

La Red N° 6, es la red N° 1, con la adición del término de precipitación del mes siguiente P(t+1) y los valores de la TSM de los 4 meses anteriores, como nuevos *inputs*. La figura N° 56, muestra los resultados de dicha Red, tanto en los conjuntos de datos de entrenamiento y del test, con los distintos números de neuronas ocultas utilizadas, que en este TFM fueron de 5, 10, 15, 20 y 25.

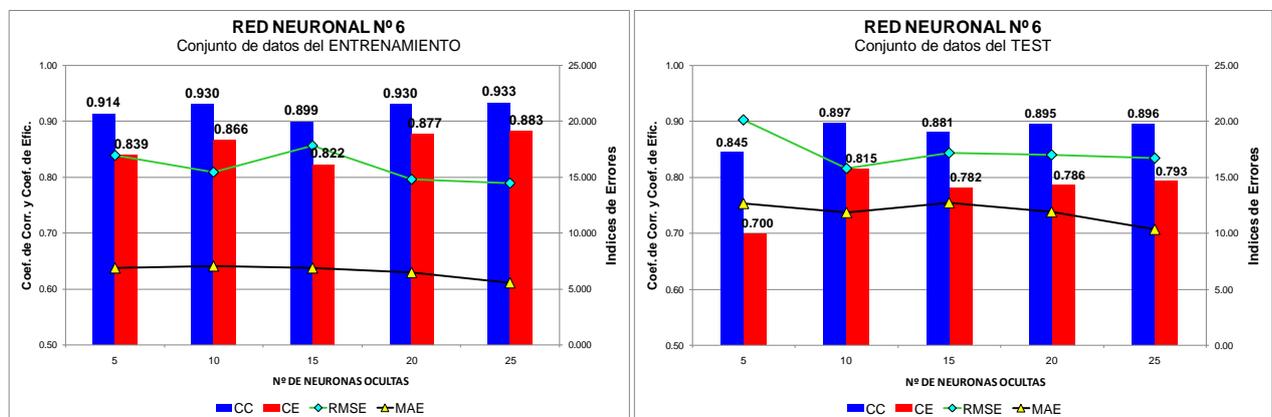


Figura 56 Índices de ajustes y errores. RN6

En el entrenamiento, todas las redes simuladas han resultado con un desempeño similar, con valores de CC de 0.910 en promedio, y con valores de CE de 0.850. En el test, las redes, han demostrados resultados muy similares, en cuanto a CC con valores alrededor de 0.89 y con relación al CE alrededor de 0.78, solo habiendo presentado valores por debajo de estos la red de 5 neuronas ocultas. Por lo tanto, ante esta situación, se selecciona a la de 10 neuronas ocultas como la de mejor desempeño, con un CC de 0.897 y un CE de 0.815.

En los gráficos de la figura 57, se presentan los resultados obtenidos en forma de caudales observados vs. caudales simulados, con la línea a 45° de simulación perfecta, de la Red N°6 con 10 neuronas ocultas, la cual ha sido seleccionada anteriormente como la de mejor desempeño. En el gráfico del test, se puede notar una cierta aproximación a la línea de 45° para los caudales bajos a medios, y una cierta dispersión en los caudales altos.

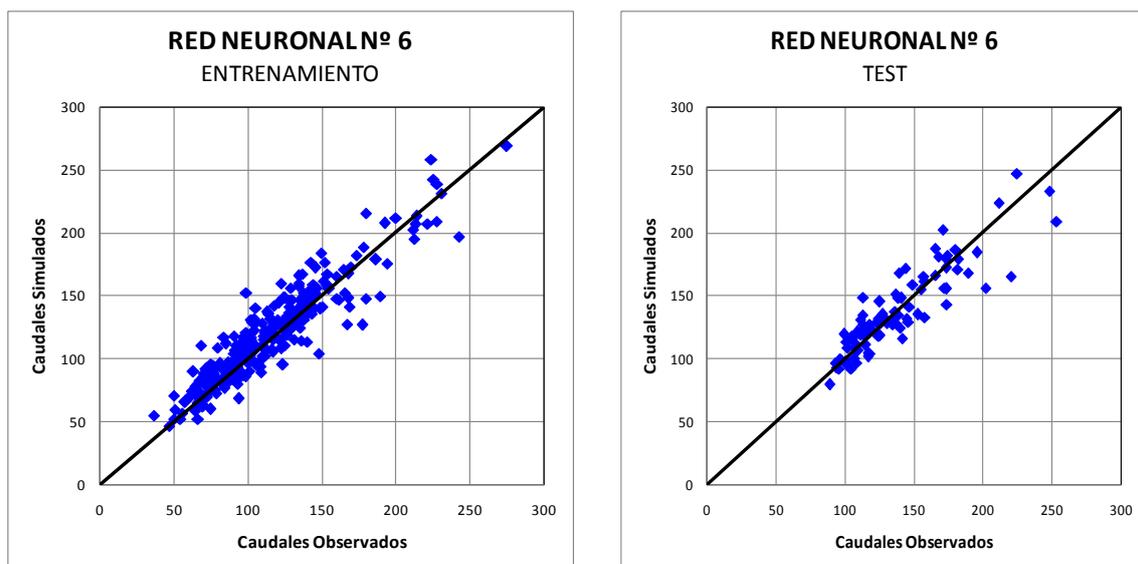


Figura 57 Caudales Observados vs. Simulados. RN6

En la figura 58, se muestran los hidrogramas de las series observadas y simuladas de la red con 10 neuronas ocultas, con todos los conjuntos de datos utilizados, los del entrenamiento, de la validación cruzada y del test.

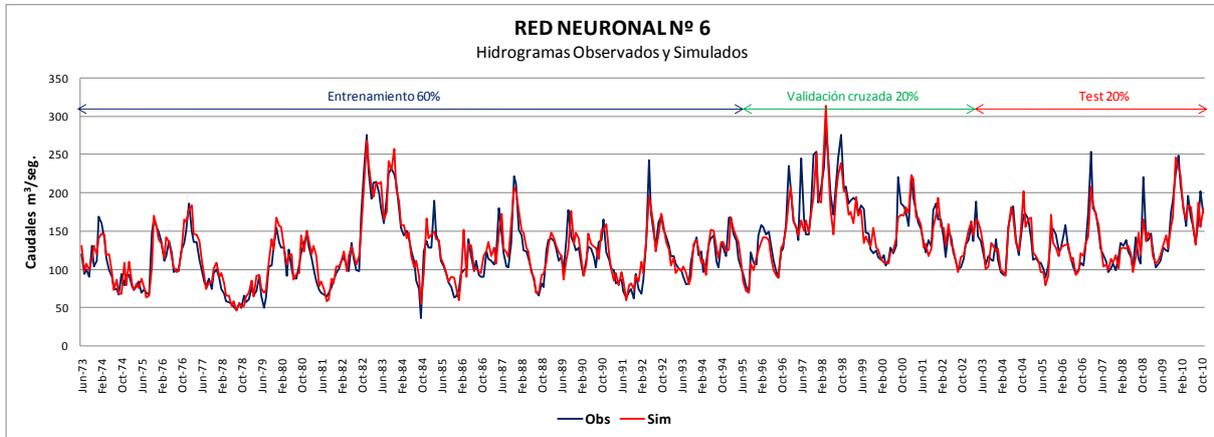


Figura 58 Hidrogramas Observados y Simulados. Serie completa. RN6

En la parte del Test, de los tres picos que se presentan (Febrero 2007, Noviembre 2008 y Enero 2010), solo en uno de ellos se tuvo un buen ajuste (Enero 2010), y ajuste satisfactorio para valores menores a los 150 m³/seg, figura 59.

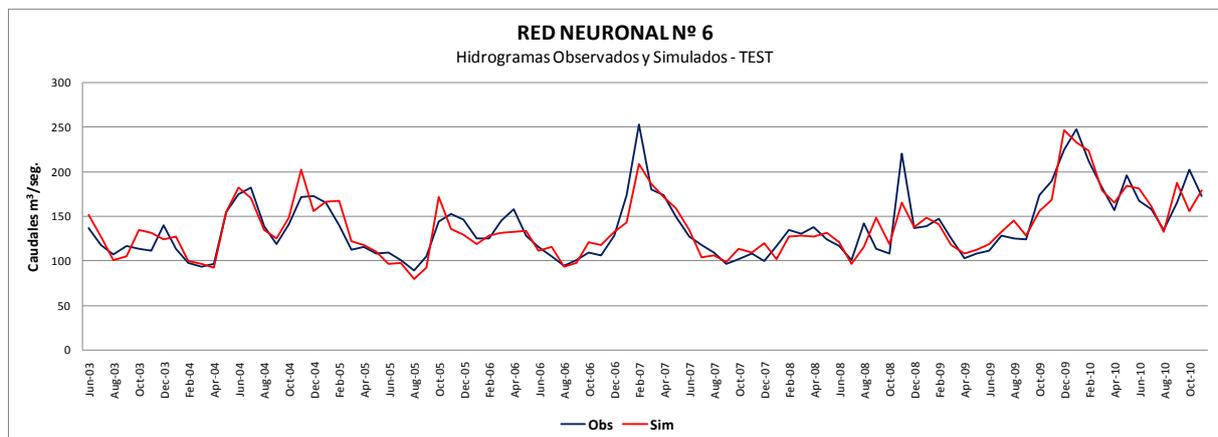


Figura 59 Hidrogramas Observados vs. Simulados. Serie del TEST. RN6

Luego de haber presentado los resultados de cada una de las redes diseñadas por separado y en función del número de neuronas ocultas, se han seleccionado a las redes de mejores desempeño, teniendo en cuenta los *inputs* y la mencionada cantidad de neuronas ocultas:

- de la RN N°1 ha sido seleccionada la red con 20 neuronas ocultas.
- de la RN N°2 ha sido seleccionada la red con 25 neuronas ocultas.
- de la RN N°3 ha sido seleccionada la red con 15 neuronas ocultas.
- de la RN N°4 ha sido seleccionada la red con 25 neuronas ocultas.
- de la RN N°5 ha sido seleccionada la red con 15 neuronas ocultas.
- de la RN N°6 ha sido seleccionada la red con 10 neuronas ocultas.

En la figura N° 60, se presenta una comparación entre las RNA seleccionadas considerando los índices de ajustes y de errores considerados en este TFM.

En la misma se puede observar, que todas las redes con el *input* de la precipitación del mes siguiente, el $P(t+1)$, que son las redes RN2, RN4 y RN6, claramente se puede apreciar, que los valores más elevados del CC fueron obtenidos con dichas redes, muy próximos a 0.900, y en el mejor caso llegó a 0.908 con la RN2.

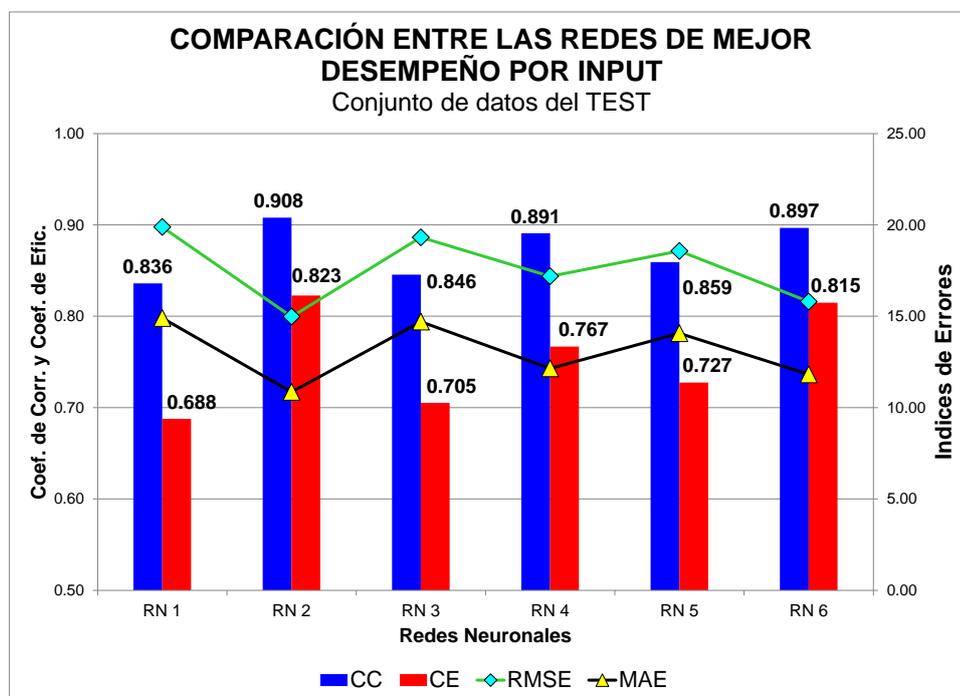


Figura 60 Índices de ajustes y de errores de las 6 mejores RNA. Series del TEST

De igual forma, con relación al CE, se puede observar que en las redes mencionadas anteriormente, la RN2, RN4 y RN6, presentaron los mejores resultados, en dos de los tres casos superaron los 0.800 y el restante resultó con un valor de 0.767, que también es considerado como satisfactorio. También, puede notarse que los índices de errores, en dichas redes, son menores que en las demás.

Analizando las redes RN1, RN3 y RN5, en las cuales no ha sido utilizada la precipitación del mes siguiente $P(t+1)$ como *input*, los valores de CC, han resultado muy similares en las tres redes, siendo de 0.859 el mejor valor alcanzado y que corresponde a la RN5. Con relación a los valores de CE, también se pueden considerar satisfactorios los resultados alcanzados, siendo de 0.727 el mayor de ellos, perteneciente de nuevo a la RN5.

Comparando con la red patrón RN1, las redes RN2 que tiene como *input* adicional el $P(t+1)$, la red RN3 que tiene como adicional la $TSM(t-4)$ y la red RN5 que tiene como *inputs* adicionales a las TSM anteriores, se ha verificado que en ambos casos se han mejorado los índices de ajustes y de errores en comparación con los obtenidos con la red RN1. Además, al comparar a las redes RN3 y RN5, se ha verificado que al utilizar los *inputs* de la TSM anteriores, se han obtenidos resultados levemente mejores que utilizando el $TSM(t-4)$ de forma única.

A continuación, se analizan los resultados obtenidos con la utilización del *input* de predicción de la precipitación del mes siguiente, $P(t+1)$, en las redes RN2, RN4 que a más del *input* $P(t+1)$ tiene como *input* adicional la $TSM(t-4)$ y la red RN6, que además del *input* $P(t+1)$ tiene como *input* adicionales a las TSM anteriores. La red de mejor desempeño de este TFM ha sido la RN2, superando a las demás redes en todos los índices de ajustes y de errores. Evaluando a las redes RN4 y RN6, la utilización de las TSM anteriores en la RN6 ha mejorado los resultados en comparación con los de la RN4, en la cual solo se utiliza la $TSM(t-4)$.

A modo de poder comparar visualmente los resultados obtenidos con las simulaciones de las seis RNA, en la figura N° 61, se presentan los hidrogramas simulados correspondientes al conjunto del TEST de cada una de las seis RNA y el hidrograma observado. En el mismo, se puede notar que todas las RNA han tenido un buen ajuste, inclusive en dos de los tres picos.

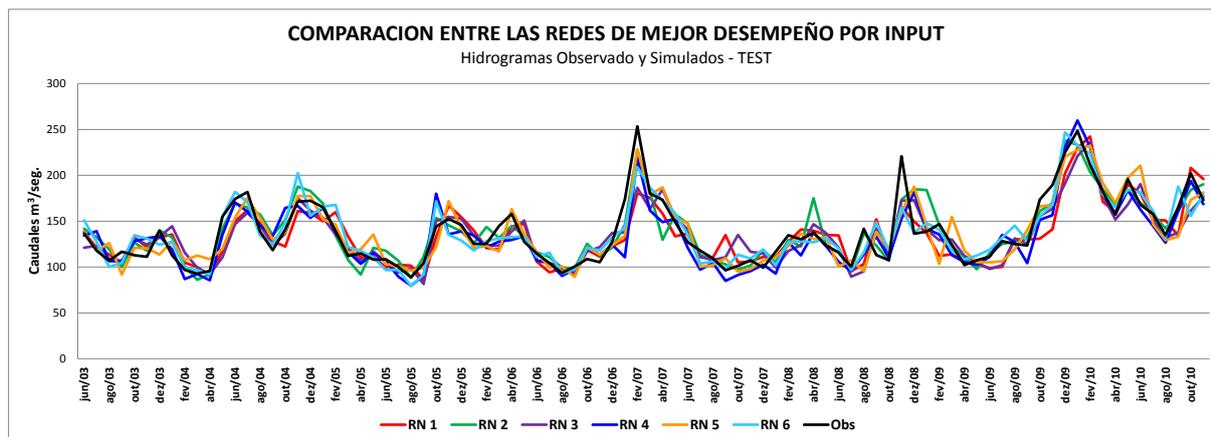


Figura 61 Hidrogramas simulados de las seis mejores RNA obtenidas. Series del TEST.

Otro análisis que fue realizado en este TFM con los resultados del test de las diferentes RNA desarrolladas a modo de poder valorar cuantitativamente la ganancia de las RNA, fue el de comparación con el modelo *Naive* o modelo trivial de persistencia.

El modelo de *Naive*, es simple de aplicar, pero nos provee una idea, una noción de poder medir cuan bueno es nuestro modelo desarrollado, comparandolo con uno que solamente es la mera suposición de que la predicción del mes siguiente es el valor del mes inmediatamente anterior.

Tabla 5 Comparación de resultados con modelo trivial Naive

ITEM	RN1			RN2			RN3		
	Sim	Naive	%mejoría	Sim	Naive	%mejoría	Sim	Naive	%mejoría
CC	0,836	0,688	21	0,908	0,688	32	0,846	0,688	23
CE	0,688	0,380	81	0,823	0,380	117	0,705	0,380	86

ITEM	RN4			RN5			RN6		
	Sim	Naive	%mejoría	Sim	Naive	%mejoría	Sim	Naive	%mejoría
CC	0,891	0,688	29	0,859	0,688	25	0,897	0,688	30
CE	0,767	0,380	102	0,727	0,380	91	0,815	0,380	115

La tabla N° 5, muestra los resultados de las comparaciones de las seis RNA desarrolladas con el modelo Naive, el cual presenta un coeficiente de correlación (CC) de 0,688 y un coeficiente de eficiencia de Nash (CE) de 0,380. La red de mejor resultado, la RNA 2, ha presentado unas mejorías de 32% en el CC y 117% en el CE. En cuanto al porcentaje de mejoría del CC, en promedio de las seis RNA, hubo un aumento del 27% en comparación con la predicción del modelo Naive, y con relación al CE, hubo en promedio de las seis RNA, una mejoría del 99% comparando con el modelo Naive.

8. Conclusiones y Recomendaciones

Este Trabajo Fin de Master consistió en la elaboración de una Red Neuronal Artificial que tenga la capacidad de realizar predicciones del caudal promedio mensual de un río de la cuenca incremental de la Central Hidroeléctrica Itaipu.

Conclusiones:

La principal conclusión de este TFM, es que las RNA son una alternativa muy eficiente para realizar predicciones de caudales mensuales en función de los resultados obtenidos con todas las redes diseñadas.

La metodología en sí, ha demostrado mucha versatilidad a la hora de plantear el problema y las diferentes soluciones, así como también una gran adaptabilidad en función de los datos que se disponen. Esto está demostrado en este TFM, con la utilización de seis RNA con diferentes *inputs* o datos de entradas.

Sobre la cantidad de neuronas ocultas en cada una de las redes con los mismos *inputs*, no se ha identificado algún patrón entre los resultados obtenidos, habiéndose encontrado que el mejor resultado en una de las redes ha salido con 10 neuronas ocultas y en otros casos con 15, 20 o 25 neuronas ocultas.

En cuanto a los *inputs* utilizados en este TFM, se han diseñado en total seis RNA, con diferentes *inputs* en cada uno de ellos, explicados anteriormente. La utilización de los *inputs* adicionales, la *TSM* y la $P(t+1)$, ha resultado en mejorar el desempeño de dichas redes, tanto en las que no han utilizado el *input* $P(t+1)$ así como en las redes que sí han utilizado como *input* a la $P(t+1)$. Por lo tanto, se concluye que la adición de ambos *inputs*, por separado y en combinación de los mismos, ha sido beneficiosa a la hora de mejorar los desempeños, en comparación con la red patrón RN1.

En comparaciones realizadas con el modelo Naive de predicción trivial, se han obtenidos mejorías en todas las seis RNA desarrolladas, destacándose las mejorías obtenidas con el Coeficiente de Eficiencia de Nash.

Recomendaciones:

La implementación de esta metodología de RNA, para la predicción de caudales mensuales en la OPH, es totalmente factible, tomando en cuenta: la disponibilidad de datos de caudales y precipitaciones observadas y de las TSM, y también que una vez implementada la red; la practicidad de la simulación para un ambiente operativo hace que la misma sea una alternativa válida.

Para complementar el estudio de toda la cuenca incremental de aguas arriba de la Itaipu, se debe implementar otros modelos de RNA en los demás ríos de la misma, a modo de que se pueda aplicar una metodología completa e integral de las predicciones de caudales mensuales para dicha cuenca.

Con relación a los resultados obtenidos con las redes que han utilizado como *inputs* las TSM, y en función de la disponibilidad de otros índices climáticos mensuales en la web de la NOAA, se recomienda la evaluación de los mismos como posibles *inputs* a las otras RNA a ser desarrolladas en futuros estudios similares.

En el caso que se decida utilizar un *input* de predicción de precipitación del mes siguiente, se debería investigar una forma de cuantificar dicho valor, por ejemplo en función de los pronósticos de una de las instituciones de Meteorología del Brasil, como ser INMET o CPTEC.

9. Referencias.

- Anmala, J., Zhang, B., & Govindaraju, R. (2000). Comparison of ANNs and empirical approaches for predicting watershed runoff. *Journal of Water Resources Planning and Management*, 126 N°3, 2517-2530.
- Cárdenas, P., & Gil, A. (2000). Modelo de pronóstico del caudal de aporte al embalse Guri utilizando variables macroclimáticas. *Seminario de Hidrología Operativa*. Salto Grande, Argentina-Uruguay.
- Dawson, C., & Wilby, R. (2001). Hydrological modelling using Artificial Neural Networks. *Progress in Physical Geography*, 80-108.
- Dawson, C., Harpham, C., & Chen, Y. (2002). Evaluation of Artificial Neural Networks techniques for flow forecasting in the river Yangtze, China. *Hydrology and Earth System*, 619-626.
- Dolling, O., & Varas, E. (2001). Artificial Neural Networks for Streamflow prediction. *Journal of Hydraulic Research*.
- Dos Santos, C. (2001). *Modelagem de bacias urbanas com redes neuronais artificiais*. Sao Paulo: Dissertação de Mestrado.
- Funahashi, K. (1989). On the approximation realization of continuous mappings by neural networks. *Neural Networks*, 183-192.
- Garbrecht, J. (2006). Comparison of three alternative ANN designs for monthly rainfall-runoff simulation. *Journal of Hydrologic Engineering*.
- García-Bartual, R. (2005). *Redes Neuronales Artificiales en Ingeniería Hidráulica y Medioambiental*. Valencia, España.
- Govindaraju, R. (2000a). Artificial Neural Networks in Hydrology. I: Preliminary Concepts. *Journal of Hydrologic Engineering*.

- Govindaraju, R. (2000b). Artificial Neural Network in Hydrology. II: Hydrologic Applications. *Journal of Hydrologic Engineering*.
- Hagan, M., Demuth, H., & Beale, M. (1996). *Neural Network Design*. United States of America: PWS Publishing Company.
- Haykin, S. (1999). *A comprehensive foundation*. New Jersey, USA.: Prentice-Hall.
- Hsu, K.-I., Hoshin, V., & Sorooshian, S. (1995). Artificial Neural Networks modeling of the rainfall-runoff process. *Water Resources Research*, 2517-2530.
- Itaipu Binacional. (1994). *Itaipu: Hydroelectric Project*. Curitiba, Brasil.: Itaipu Binacional.
- Jaime, P., & Menéndez, A. (2003). *Vinculación entre el caudal del río Paraná y el fenómeno de El Niño*. Buenos Aires, Argentina.: Instituto Nacional del Agua.
- Kişı, Ö. (2007). Streamflow Forecasting Using Different Artificial Neural. *JOURNAL OF HYDROLOGIC ENGINEERING*, 532-539.
- Larentis Gama, D., Pedrollo, O., & Dornelles, F. (2007). Avaliacao de Incertezas na previsao de vazoes utilizando redes neuronais artificiais. *Simposio Brasileiro de Recursos Hídricos*. Sao Paulo.
- Nilsson, P., Uvo, C., & Berndtsson, R. (2005). Monthly runoff simulation: Comparing and combining conceptual and neural networks models. *Journal of Hydrology*, 344-363.
- Ochoa, J. (2002). *Modelo estocástico de redes neuronales para la síntesis de caudales aplicados a la gestión probabilística de sequías*. Valencia, España.: Universidad Politécnica de Valencia.
- Pontes, P., Fan, F., Collischonn, W., Buarque, D., & Sorribas, M. (2012). Calibracao e verificacao do modelo hidrológico MGB-IPH para a bacia do Paraná. *XI Simposio de Recursos Hidricos do Nordeste*. Joao Pessoa, Brasil.

- Póveda, G., Mesa, O., Carvajal, L., Hoyos, C., Mejía, J., Cuartas, L., y otros. (2002). *Predicción de caudales medios mensuales en ríos colombianos usando métodos no lineales*. Bogotá, Colombia.: Universidad Nacional de Colombia.
- Prada-Sarmiento, F., & Obregón-Neira, N. (2009). Forecasting of monthly streamflow based on Artificial Neural Networks. *Journal of Hydrologic Engineering*, 1390-1395.
- Pujol, L. (2009). *Predicción de caudales en tiempo real en grandes cuencas utilizando redes neuronales artificiales*. Valencia, España.: Universidad Politécnica de Valencia.
- RHAMA Consultora, PIASEX Consultora, & Gaete, P. (2009). *Revisao da enchente máxima provável de Itaipu: Area incremental*. Foz do Iguacu, Brasil.: Itaipu Binacional.
- Rivarola, J. (1994). Caracterización de la cuenca de Itaipu. *Seminario técnico del área de Operación*. Hernandarias, Paraguay.: Itaipu Binacional.
- Rivarola, J. (2008). *The study of climate change on the hydrology of the Itaipu Hydropower basin*. Florencia, Italia: Universidad de Florencia.
- Solomatine, D., See, L., & Abrahart, R. (2008). *Practical Hydroinformatics, Computational Intelligence and Technological Developments in water applications*. Berlin, Germany.: Springer.
- Wilby, R., Abrahart, R., & Dawson, C. (2003). Detection of conceptual model rainfall-runoff processes inside an artificial neural network. *Hydrological Sciences*, 163-181.

10. Anexo.

Pesos y umbrales de las mejores 6 RNA

RN1

[-0.1715 0.98317 -2.1677 1.4811 -1.202 -0.19692;
-0.32393 0.74851 -0.015516 0.35401 -0.66531 1.8368;
1.0222 -0.044881 1.4463 -0.97117 -0.82077 0.0049714;
1.6706 -0.63575 -0.89183 -0.94414 -2.3296 0.97661;
-0.70766 -1.6532 0.49854 1.1369 -0.30941 0.81415;
-1.0824 -1.3217 -1.3701 -1.5631 -0.55667 0.47242;
1.0463 0.67545 0.93148 -1.5889 0.65797 -1.1319;
0.72285 -1.24 -0.68937 1.4075 1.496 -0.90085;
-0.74925 0.88779 1.2074 0.68119 1.3075 -0.49436;
-0.42829 1.3015 -0.44968 0.72507 1.1075 1.3126;
-1.2518 0.47289 -0.29328 -1.468 0.88859 1.8758;
0.27702 0.135 2.4565 0.74791 -2.544 1.2855;
-0.95968 0.79234 -0.6235 -1.0393 0.90779 1.2835;
-1.884 1.6827 -0.94796 0.52899 -0.18673 -0.39342;
1.3647 -0.018663 0.6484 0.35909 -1.4692 1.0591;
1.349 -1.2217 -0.83188 0.73796 0.72703 0.13831;
1.1798 -0.84479 1.2712 0.41713 -0.91153 -0.64221;
0.78654 1.9731 0.17922 0.99262 -1.1925 -0.0024824;
-0.2276 -0.34235 -0.077994 1.926 -0.77891 1.2507;
-0.15826 -0.80314 -1.3843 1.1454 -0.14887 -1.5245]

[0.87151 0.57413 0.706 -0.68099 -0.87261 0.13453 -0.63105 -0.64802 0.48618 -0.10851
-0.5218 0.92224 0.19688 -1.0781 -1.2839 0.53481 -0.72961 0.17795 0.49407 -0.87981]

[-1.8428;
-1.8182;
-2.5211;
-1.8304;
0.9909;
0.3809;
-0.86292;
1.0405;
-0.71139;
0.64766;
-1.0201;
0.90877;
-0.69973;
-0.5529;
0.7189;
1.5997;
1.7903;
2.0162;
2.5816;
-2.7143]

[0.47426]

RN2

[-0.23598 -1.0181 -1.7956 -1.3201 2.0625 1.3103 -1.7574;
 3.0226 -0.96743 -1.2899 0.52896 -0.54235 0.73305 -2.5142;
 1.0723 -0.30644 -1.8598 0.85808 0.023269 0.27538 0.22137;
 4.9159 -0.64752 0.20377 1.167 -0.74629 1.7544 -0.89922;
 -2.426 -0.48698 3.3986 0.37043 -1.5639 -1.3694 1.3717;
 0.045227 -0.56665 0.58633 -1.6709 0.17121 -1.0053 -4.1274;
 -2.362 1.8055 0.58288 -0.31289 0.55191 0.067951 0.18274;
 -1.6479 -1.3386 -2.3499 -2.0837 -1.1551 0.54926 -2.1748;
 -3.776 0.023798 -0.56239 -1.3066 -2.8511 -0.33753 -0.82981;
 2.2302 0.62341 4.8411 2.2491 -3.4457 1.6794 1.3218;
 1.2427 1.754 1.3116 -1.6897 2.2842 0.14205 -0.53116;
 2.2825 2.1906 2.8237 1.1167 1.422 -2.1227 1.828;
 2.7698 3.2389 0.46175 4.1463 1.1459 -1.5793 -0.23249;
 0.10826 1.1142 -2.0065 0.12412 1.0791 1.24 -1.2975;
 -1.254 -1.8005 -1.3406 1.6355 -0.33987 -0.1691 -0.72775;
 -0.6367 -1.1747 0.92228 1.7649 -0.41504 2.6723 -2.4809;
 -0.27273 -0.065535 -1.801 -2.1077 0.38952 -0.077725 0.67789;
 1.0136 -3.2986 -3.5561 -2.4638 0.043284 -0.79311 -1.9948;
 0.80351 1.5922 -0.42032 -0.075154 -1.9046 -1.2904 1.3035;
 0.63876 -2.1988 -1.6449 -0.36515 1.8044 1.4127 1.0559;
 0.1416 2.2028 0.64267 4.8349 -0.91259 0.58189 -3.0945;
 -0.98845 -1.4223 -0.17683 0.41754 -1.2334 -1.3005 0.9905;
 -0.053729 -0.72858 1.522 1.0349 3.7213 -0.80549 3.6094;
 2.1162 0.52073 -1.2156 0.97973 -1.1864 0.20348 0.45245;
 1.9401 -0.74784 -0.83495 0.80901 -1.9475 1.2065 1.7134]

[0.090439 0.33474 1.5808 0.27477 1.6621 -0.060698 0.52407 0.28971 -0.19431 -0.21185
 0.17111 0.21224 -0.213 -0.56644 -0.22503 0.072006 -0.41847 -0.30082 0.04237 0.12108 -
 0.23302 -0.34496 -0.10991 0.41269 0.0060123]

[-0.54462;
 -2.1602;
 -1.767;
 -0.89623;
 2.5947;
 0.061647;
 0.78062;
 2.1408;
 3.8785;
 -1.2461;
 -1.1321;
 -1.1197;
 -0.72733;
 0.82899;
 -2.2155;
 0.79788;
 -0.61713;
 2.1644;
 0.72971;
 2.0325;
 1.5955;
 -2.271;
 -0.15186;
 2.8666;
 1.7892]

[-0.54701]

RN3

[-1.4061 0.060949 -0.17831 -0.59085 0.96413 -0.8855 -0.4275;
1.783 1.1369 -1.315 -0.47704 1.0193 -1.0223 -1.0663;
1.2116 -1.4983 -0.66556 0.55974 -0.52198 -0.86637 -1.7929;
2.6195 1.6525 -1.0093 1.4558 -2.8887 2.6053 0.62806;
3.1631 -0.67747 -1.9693 1.6475 1.8116 -0.5087 1.6947;
-0.87682 0.48021 -0.20334 -1.5561 -1.1108 0.18791 2.2181;
-1.2387 -0.064031 3.5616 -0.49765 -2.252 1.6492 0.79084;
2.7402 0.28208 -3.548 -1.0887 1.6236 1.6825 0.36112;
0.50164 -0.046559 -2.0073 -1.8283 -0.98604 -1.3276 1.8675;
-1.1512 -0.092551 0.070463 1.5485 -0.26757 -0.85532 0.35488;
-1.6138 1.1055 0.71526 4.1412 -2.0182 0.7814 0.0079994;
1.7336 -1.4714 -1.2739 1.6443 0.53491 0.12887 -0.36995;
0.43609 -0.71997 3.013 -1.1649 3.5639 -1.6975 -0.8737;
-0.72356 -1.7392 -1.1961 1.8535 2.1374 -1.1062 -0.64371;
2.8553 -2.6519 -1.1125 1.4191 -0.50053 0.66231 -2.1739]

[-0.69386 0.14317 -0.1248 0.13875 0.15835 -0.0068527 0.21269 -0.32468 0.014064 -0.36006
0.031498 1.0632 0.17273 0.17263 -0.29525]

[2.7005;
-1.4195;
-1.1078;
1.6884;
0.28959;
-2.0128;
0.039775;
0.5035;
-0.76009;
0.29145;
-0.29829;
3.2152;
1.563;
-0.00066904;
2.9683]

[-0.087745]

RN4

[1.018 -0.78212 -0.38544 0.39193 -1.3564 -0.77387 -0.25627 -0.89944;
0.80302 0.43217 1.7461 -1.212 0.42997 -0.8576 0.22132 1.2291;
-2.3136 0.056711 -0.50779 1.515 -0.30375 0.057742 0.035899 -0.24897;
1.7237 0.67948 -1.5036 0.70174 0.23681 0.2179 -0.17877 -0.1084;
-0.35955 0.99062 0.56866 -0.083808 -1.5926 0.22091 -0.41348 0.56293;
0.58098 1.5637 -0.63928 1.3141 0.57213 -0.37672 -0.23285 0.96817;
-1.0869 -1.4235 0.31236 -0.78021 -0.22865 -0.93814 -0.29375 0.47293;
0.25531 -0.38045 -0.5823 -1.097 -1.459 -0.96869 0.025036 0.1907;
0.89788 -0.2668 0.71714 0.55523 -0.70975 1.6211 1.038 1.1719;
-0.55937 0.63327 -1.3476 1.8175 -0.69237 0.43589 0.37445 -0.15036;
0.78765 0.36289 -1.5809 0.49768 -0.011613 0.78097 -0.44736 -0.10028;
0.68509 -1.6034 1.2805 -0.8921 0.30395 0.89715 -0.68151 -0.20206;
1.553 -0.22109 -1.6398 -0.9129 -1.3193 -0.33918 0.81545 0.41772;
-0.10272 0.55962 0.4982 -1.5949 0.3285 -1.6311 -1.1718 1.1446;
0.38817 -1.2461 -0.58949 -1.2266 -0.72025 0.37368 -0.011869 0.49926;
0.7455 1.5759 0.9728 -1.8763 -0.20091 -0.41736 -0.89206 0.76198;
-0.17094 -0.79151 -1.7486 -0.046689 -1.4182 -0.48603 -0.28742 0.1154;
-1.2902 0.4221 1.6911 0.81811 -1.9333 -0.24875 -0.5937 -0.15231;
0.64966 -0.73086 -1.9183 0.38762 -0.41293 -0.9612 0.14831 -1.4748;
0.41454 -1.1181 1.411 0.89088 -1.2932 -0.4411 -0.27059 1.038;
0.63552 0.071077 0.0095677 -1.0435 0.18521 -0.23897 -0.31131 -0.2576;
-0.97662 -0.44536 0.59683 -0.95557 -0.19306 0.11861 -1.1139 0.89651;
-0.078701 0.97284 -0.97826 -0.27155 0.54714 0.032055 -0.028483 1.4964;
-0.75166 -2.0991 0.10235 0.65625 0.087808 0.022079 -0.03599 1.0261;
0.077118 0.82395 0.31774 -0.1938 0.98606 -1.5448 0.38128 1.011]

[-0.43847 0.43711 0.43564 0.67769 -0.42155 -0.31492 -0.25234 -0.2099 -0.16519 0.21479 -
0.48902 0.51584 0.49706 0.068529 -0.45236 0.18808 -0.010183 0.14442 0.010208 -0.033104 -
1.1 0.22273 0.45641 -0.27027 0.21977]

[-2.8046;
-1.9106;
2.2606;
-1.1611;
2.1279;
-1.3039;
1.7813;
-0.63472;
-1.3402;
1.0404;
-0.086749;
-0.44297;
-0.3279;
-0.12501;
-0.36914;
0.057645;
-0.8185;
-1.1146;
0.047391;
0.70456;
0.68729;
-0.66421;
-1.5784;
-1.8252;
2.013]

[1.0267]

RN5

[1.5525 1.6037 1.4363 0.5911 0.041028 -2.0185 -0.53634 -1.628 0.81962 1.7016;
2.0707 -0.023124 -1.8013 -0.013219 0.15391 0.25221 -1.4381 1.3033 1.3441 0.36258;
1.3193 -1.0933 -0.36494 1.7665 -2.0243 0.49937 -0.48566 -0.17155 0.57318 0.11478;
0.5379 0.46852 0.78744 -0.3146 -0.83418 0.22361 0.39701 1.0468 -0.32504 -0.5167;
-0.57056 0.27209 0.54488 2.1384 -0.39283 0.28833 0.49694 0.083754 -0.60742 -0.078553;
-0.68266 0.81916 1.413 0.6436 -0.37152 0.096732 0.39131 -0.32105 -2.1802 -0.8576;
-1.6687 -1.0886 -0.84863 0.91673 -1.5864 0.00056363 0.20364 0.55774 1.3504 -0.063736;
1.3397 0.62018 0.30653 0.70661 2.2859 -0.40007 -0.28617 -0.35223 -0.4335 0.65984;
0.1221 0.40863 -1.1879 1.1789 -0.57839 0.14177 -0.54783 1.9767 -0.08241 1.8056;
0.64717 -0.21796 0.99366 -1.5644 -0.92592 -0.60532 1.7506 0.52164 1.1661 0.39508;
0.11637 -2.4613 3.0853 -0.23777 0.67793 -0.85212 -0.73607 0.64984 -0.73918 -0.11002;
-1.0658 -0.14024 -0.61998 -0.0084609 2.5295 -0.26269 1.6745 0.36434 -0.9579 1.0047;
0.75716 -1.1409 -1.262 -1.1835 -0.23765 1.0137 1.1987 0.44485 1.2072 1.0766;
0.8353 0.070827 0.29637 -1.3634 1.5078 1.0681 1.4972 0.62831 -1.425 -0.99403;
0.5348 -0.97988 -1.2122 -1.1036 -0.7567 1.5862 -0.37358 -1.1817 0.82966 0.38394]

[0.22397 0.41018 -1.817 0.04561 0.76749 0.34749 0.21851 0.27658 -0.070352 0.22248 0.21005
-0.28369 0.94384 -0.16952 0.29798]

[-2.451;
-1.6926;
-1.5821;
-1.4626;
-0.43625;
0.48244;
-0.071271;
1.1002;
0.84451;
0.072449;
0.67413;
0.08235;
-1.9202;
1.7823;
1.3435]

[-0.2827]

RN6

[-2.1615 -1.2236 2.582 -0.86173 2.9467 -1.1148 -0.52163 -0.45831 -1.3424 -1.8619 1.0135;
5.0824 1.7969 0.9614 -3.4213 -0.34894 -1.4209 2.5288 -2.0259 1.5057 0.19825 2.923;
0.10929 -0.4817 1.6148 -0.867 0.82251 -0.059233 -0.66662 0.29482 -0.0015772 -0.42469
0.25999;
-3.3552 -0.75292 1.0487 -0.98591 0.68897 -3.3215 0.25551 0.70387 -0.75906 0.37778 0.23251;
-0.89533 2.7418 -2.8948 -0.50508 -1.4497 -0.14075 1.9255 1.0587 -2.8994 -1.3324 0.25368;
-0.27647 0.97569 -4.2415 0.63124 2.1609 -1.1466 2.2514 -0.5921 -0.16117 1.5628 -0.38616;
-0.39486 0.92266 0.34152 1.6378 -1.2142 -1.4624 1.6375 -0.38989 0.85 2.0614 -2.0693;
0.81339 0.083946 0.33863 0.20908 2.3899 0.17349 2.6926 1.5551 -1.254 0.66382 4.3211;
0.83106 3.9416 -3.9712 -1.4469 -4.7306 2.9055 -0.064422 0.013714 0.5214 -1.1665 -4.8676;
-2.3733 0.90411 2.8335 0.52133 -1.3796 -0.18425 0.42241 -1.7735 -1.0126 -1.2719 1.2936]

[-0.21704 -0.045103 0.80974 -0.11393 0.13167 0.2598 0.25781 0.12867 -0.15441 0.26002]

[-0.34225;
-0.73545;
0.48522;
0.51811;
2.9604;
-1.0573;
-2.1691;
3.0017;
1.5342;
-1.1555]

[0.11805]