

**UNIVERSIDAD NACIONAL AGRARIA
LA MOLINA
ESCUELA DE POSGRADO
DOCTORADO EN INGENIERÍA Y CIENCIAS
AMBIENTALES**



**“USO DE REDES NEURONALES ARTIFICIALES PARA
OPTIMIZAR LA DOSIFICACIÓN DE COAGULANTES EN LA
PLANTA DE TRATAMIENTO DE AGUA POTABLE -
HUANCAYO”**

**Presentada por:
ANIEVAL CIRILO PEÑA ROJAS**

**TESIS PARA OPTAR EL GRADO DE *DOCTORIS PHILOSOPHIAE* EN
INGENIERÍA Y CIENCIAS AMBIENTALES**

Lima - Perú

2016

**UNIVERSIDAD NACIONAL AGRARIA
LA MOLINA**

ESCUELA DE POSGRADO

**DOCTORADO EN INGENIERÍA Y CIENCIAS
AMBIENTALES**

**“USO DE REDES NEURONALES ARTIFICIALES PARA
OPTIMIZAR LA DOSIFICACIÓN DE COAGULANTES EN LA
PLANTA DE TRATAMIENTO DE AGUA POTABLE -
HUANCAYO”**

TESIS PARA OPTAR EL GRADO DE

Doctoris Philosophiae (Ph. D.)

Presentada por:

ANIEVAL CIRILO PEÑA ROJAS

Sustentada y aprobada ante el siguiente jurado:

Dra. Rosemary Vela Cardich
PRESIDENTA

Ph D. Lizveth Flores del Pino
PATROCINADORA

Dr. Víctor Meza Contreras
MIEMBRO

Dra. Delia Gamarra Gamarra
MIEMBRO EXTERNO

DEDICATORIA

A mi madre Timotea que siempre me impulsó a buscar la verdad y con su dulzura y fortaleza construyó mis bases personales y académicas.

AGRADECIMIENTO

Mi profundo reconocimiento y gratitud a la Ph. D. Lisveth Flores del Pino, asesora del presente trabajo de investigación por su asesoramiento, motivación y enseñanza desde la elaboración del proyecto hasta la culminación de mi tesis doctoral.

Mi mayor reconocimiento y gratitud a la excelente plana docente del Doctorado en Ingeniería y Ciencias Ambientales de la Universidad Nacional Agraria La Molina por sus orientaciones, exigencias e integridad como profesionales y personas.

A la empresa SEDAM Huancayo por las facilidades dadas en la obtención de las pruebas y los resultados en sus laboratorios y Planta de tratamiento.

A mi esposa María Mercedes y a mis hijos Joel, Andrés, Sybill y Tomás por su apoyo moral, por los sacrificios y carencias en mi ausencia durante el periodo del desarrollo del Doctorado.

ÍNDICE

I.	INTRODUCCIÓN.....	1
1.1.	Diagnóstico del recurso hídrico.....	3
1.1.1.	Ubicación geográfica.....	3
1.1.2.	Hidrografía.....	4
1.2.	Fuente y captación de agua para la planta de tratamiento.....	5
1.2.1.	Captaciones de agua para la planta de tratamiento.....	5
1.3.	Planta de tratamiento de agua potable.....	6
1.4.	Procesos de tratamiento de agua potable en Huancayo.....	7
1.5.	Alcance de la investigación.....	8
1.6.	Objetivo de la investigación.....	8
II.	REVISIÓN DE LA LITERATURA.....	9
2.1.	Antecedentes de la investigación.....	9
2.2.	El proceso de coagulación.....	11
2.3.	Fundamentos teóricos para la investigación.....	14
2.3.1.	Coagulación.....	14
2.3.2.	Mecanismo de la coagulación.....	15
2.3.3.	Remoción de turbiedad.....	19
2.3.4.	Factores que influyen en la coagulación.....	20
2.3.5.	Condiciones para una buena reacción del coagulante.....	23
2.3.6.	Tipos de coagulación.....	24
2.4.	Aplicación práctica de los coagulantes.....	26
2.4.1.	Requisitos principales:.....	26
2.4.2.	Verificación del caudal de tratamiento.....	26
2.4.3.	Dosificación de productos químicos.....	27
2.5.	Calidad de agua.....	28
2.5.1.	Características organolépticas.....	29
2.5.2.	Características microbiológicas y parasitológicas.....	29
2.6.	Principios de la red neuronal artificial.....	30
2.6.1.	Redes neuronales.....	30
2.6.2.	Estructura de un sistema neuronal artificial.....	33

2.6.3.	Modelo de neurona artificial.....	33
2.6.4.	Entradas y salidas	35
2.6.5.	Pesos sinápticos	35
2.6.6.	Regla de propagación	35
2.6.7.	Función de activación.....	36
2.6.8.	Función de salida	41
2.6.9.	Arquitectura de una red neuronal	41
2.6.10.	Aprendizaje	42
2.6.11.	Fase de entrenamiento.....	43
2.6.12.	Fase de operación.....	43
2.7.	Redes neuronales con conexión hacia delante	43
2.7.1.	Perceptrón.....	44
2.7.2.	Adaline / Madaline	45
2.7.3.	Perceptrón multicapa	45
2.8.	Entrenamiento de redes neuronales	46
2.8.1.	Métodos de gradiente descendente	47
2.8.2.	El algoritmo Backpropagation.....	47
2.8.3.	Deducción del algoritmo <i>Backpropagation</i>	48
2.8.4.	Modos de entrenamiento	52
2.8.5.	Aceleración del aprendizaje.....	53
2.9.	Generalización	55
2.10.	Tipos especiales de redes neuronales.....	57
2.10.1.	Redes multinivel siempre hacia adelante.....	58
2.10.2.	La arquitectura MLF	58
2.10.3.	La arquitectura GRN.....	59
2.10.4.	Diseño de la red neuronal artificial.....	59
III.	MATERIALES Y MÉTODOS	61
3.1.	Lugar de ejecución.....	61
3.2.	Configuración de las redes neuronales artificiales.....	61
3.2.1.	Configuración de la red neuronal artificial.....	63
3.2.2.	Prueba de la red neuronal artificial.....	63

3.3.	Método <i>Prueba de Jarras</i>	64
3.4.	Materiales y equipos	65
3.5.	Reactivos.....	66
IV.	RESULTADOS Y DISCUSIÓN	67
4.1.	Análisis de las variables independientes consideradas en la Red Neuronal	67
4.1.1.	Características de ingreso y salida de la turbidez	67
4.1.2.	Características de ingreso y salida del pH	69
4.1.3.	Características de ingreso y salida del total de sólidos disueltos (TDS)	71
4.1.4.	Características de ingreso y salida de la conductividad ($\mu\text{S}/\text{cm}$)	73
4.1.5.	Características de ingreso y salida del color (UCV).....	75
4.2.	Configuración de la arquitectura de la red óptima.....	77
4.2.1.	Red neuronal con una capa oculta de cinco nodos.	77
4.2.2.	Red neuronal con dos capas ocultas (6 y 5 neuronas).	80
4.2.3.	Red neuronal con una capa oculta de regresión generalizada (GRN)	83
4.3.	Evaluación de la red neuronal óptima.....	86
4.4.	Impactos de las variables en el modelo seleccionado de regresión generalizada .	87
V.	CONCLUSIONES	89
VI.	RECOMENDACIONES	90
VII.	REFERENCIAS BIBLIOGRÁFICAS	91
VIII.	ANEXOS	95

ÍNDICE DE CUADROS

Cuadro 1: Límites máximos permisibles de parámetros de calidad organoléptica	29
Cuadro 2: Límites máximos permisibles de parámetros microbiológicos y parasitológicos	30
Cuadro 3: Medidas estadísticas de la turbidez.....	68
Cuadro 4: Medidas estadísticas del pH.....	70
Cuadro 5: Medidas estadísticas de los sólidos disueltos.	72
Cuadro 6. Medidas estadísticas de conductividad.	74
Cuadro 7: Medidas estadísticas del color de agua.	76
Cuadro 8: Resumen del entrenamiento de la red con una capa oculta de cinco nodos.	78
Cuadro 9: Resumen de la Prueba con la red de una capa con cinco nodos	79
Cuadro 10: Resumen del entrenamiento de la red con dos capas ocultas	81
Cuadro 11: Resumen de la Prueba con la red de una capa	82
Cuadro 12: Resumen del entrenamiento con la red de regresión generalizada (GRN)	84
Cuadro 13: Resumen de la prueba con la red de regresión generalizada	85
Cuadro 14: Evaluación de la mejor configuración de la red neuronal	87
Cuadro 15: Análisis de impacto de variables independientes.....	88

ÍNDICE DE FIGURAS

Figura 1: Ubicación de la Sub cuenca del Río Shullcas	4
Figura 2: Mapa de la Red Hidrográfica de la subcuenca del río Shullcas.....	5
Figura 3: Captación de agua para la Planta en Chamisería	6
Figura 4: Planta de tratamiento de agua de Vilcacoto	7
Figura 5: Esquema de procesamiento de agua potable.....	12
Figura 6: Proceso de coagulación.....	13
Figura 7: Anulación de cargas eléctricas en la superficie del coloide.	15
Figura 8: Fuerzas de Van der Waals.....	16
Figura 9: Atrapamiento de las partículas en un floc	17
Figura 10: Efecto de puente de las partículas en suspensión.....	18
Figura 11: Diagrama de Remoción de Turbiedad.....	20
Figura 12: Condiciones de Mezcla	24
Figura 13: Coagulación por Adsorción.....	25
Figura 14: Coagulación por Barrido	26
Figura 15: Estructura de una neurona biológica.....	31
Figura 16: Modelo de neurona artificial	34
Figura 17: Función escalón.....	37
Figura 18: Función mixta caso a.....	38
Figura 19: función mixta: caso b	38
Figura 20: función hiperbólica	39

Figura 21: Función sigmoïdal.....	40
Figura 22: función Gaussiana	40
Figura 23: Arquitectura común de una red neuronal artificial.....	41
Figura 24. Generalización de situación idealizada	56
Figura 25. Generalización. Situación real	57
Figura 26: Arquitectura red multinivel hacia adelante (MLF).	58
Figura 27: Arquitectura Red de regresión generalizada (GRN)	59
Figura 28: Metodología para la investigación	62
Figura 29: Equipo de Prueba de Jarras	65
Figura 30: Evaluación promedio mensual de turbidez	67
Figura 31: Diagrama de caja del comportamiento de la turbidez.....	69
Figura 32: Evaluación promedio mensual de pH	70
Figura 33: Diagrama de caja del comportamiento del pH.....	71
Figura 34: Evaluación promedio mensual del total de sólidos disueltos.....	72
Figura 35: Diagrama de caja del comportamiento del total de sólidos disueltos	73
Figura 36: Evaluación promedio mensual de la conductividad eléctrica	74
Figura 37: Diagrama de caja del comportamiento de la conductividad	75
Figura 38: Diagrama de caja del comportamiento del color (UCV)	77
Figura 39: Configuración de red con tres capas (una oculta de cinco neuronas)	78
Figura 40: Regresión lineal de la prueba de red con tres capas (una oculta)	80
Figura 41: Configuración de red neuronal con cuatro capas (dos ocultas)	80

Figura 42: Regresión lineal de entrenamiento de red con cuatro capas (dos ocultas).....	82
Figura 43: Regresión lineal de la prueba de red con cuatro capas (dos ocultas).....	83
Figura 44: Configuración de la red neuronal de regresión generalizada (GRN).....	83
Figura 45: Regresión lineal de entrenamiento de red de regresión generalizada GRN (dos ocultas).....	85
Figura 46: Regresión lineal de prueba de red de regresión generalizada GRN (dos ocultas)	86

ÍNDICE DE ANEXOS

ANEXO N° 1. CONTROL MENSUAL DE JULIO 2012 A MAYO 2013 PARA LA PRUEBA Y ENTRENAMIENTO DE LA RED OBTENIDOS CON LA PRUEBA DE JARRAS	96
ANEXO N° 2. DATOS DE SALIDA DE LA DOSIS (ppm) EN EL ENTRENAMIENTO Y PRUEBA DE RED NEURONAL DE TRES CAPAS CON UNA OCULTA DE CINCO NEURONAS	107
ANEXO N° 3. DATOS DE SALIDA DE LA DOSIS (ppm) EN EL ENTRENAMIENTO Y PRUEBA DE RED NEURONAL DE TRES CAPAS CON UNA OCULTA DE CINCO NEURONAS	112
ANEXO N° 4. DATOS DE SALIDA DE LA DOSIS (ppm) EN EL ENTRENAMIENTO Y PRUEBA DE RED NEURONAL DE TRES CAPAS DE REGRESIÓN GENERALIZADA (GRNN)	117

RESUMEN

En la investigación se utilizaron las redes neuronales artificiales como herramienta para optimizar la cantidad de coagulante (Al_2SO_4) que se utiliza en el tratamiento del agua potable de la empresa SEDAM de la ciudad de Huancayo – Perú, donde la calidad del agua al ingreso a la planta de tratamiento tuvo variabilidad permanente de turbidez debido a las precipitaciones fluviales que se presentaron generalmente en los meses de octubre a marzo. Este fenómeno meteorológico alteró en corto tiempo las características físicas y químicas del agua dificultando su tratamiento. Se utilizó en el laboratorio el ensayo denominado *Prueba de Jarras* para determinar la dosis de coagulante a emplear durante un periodo de once meses, con muestreo aleatorio diario. Las variables consideradas para el estudio fueron la turbidez, el pH, la conductividad, el color y sólidos disueltos totales con una temperatura promedio de 10 °C y un caudal promedio de 148 l/s. Los cálculos obtenidos fueron utilizados para entrenar y probar dosis óptimas de coagulante haciendo uso de redes neuronales artificiales con tres topologías específicas: Red de tres capas (entrada de cinco neuronas, oculta de cinco neuronas, salida una neurona), Red de cuatro capas (entrada de cinco neuronas, dos ocultas de seis y cinco neuronas, salida una neurona) y Red de cuatro capas con dos ocultas llamada también de regresión generalizada (una de entrada con cinco neuronas, dos capas ocultas, en la primera se adiciona una neurona por cada caso entrenado y en la segunda oculta dos neuronas receptoras para regresión y una capa de salida con una neurona). Se concluyó que la topología más adecuada fue la última con una asertividad de 96.9 por ciento frente a los datos reales y en su entrenamiento se obtuvo una correlación de 98.4 por ciento evidenciando además que los factores más influyentes al modelo son: color, turbidez y pH. La red seleccionada finalmente permitió predecir la dosificación de coagulante óptimo con una probabilidad de error máximo de 1.6 por ciento y en tiempo real con nuevos valores de entrada en el agua a tratar sin necesidad de recurrir a la *Prueba de Jarras* el cual sólo se realiza posteriormente para enriquecer su aprendizaje.

Palabras claves: Red neuronal, agua, optimización, coagulante (Al_2SO_4)

ABSTRACT

In the research of artificial neural networks is used as a tool to optimize the amount of coagulant (Al_2SO_4) used in treating drinking water company SEDAM city of Huancayo, where the quality of water entering the treatment plant is highly unstable permanent river variability due to rainfall occurring especially in the months from October to March, these meteorological phenomena in a short time alter the physical and chemical characteristics of water treatment difficult. *jar testing* was used in the laboratory to determine the dose of coagulant to be used for a period of eleven months from July 2012 to May 2013, with daily random sampling. The variables considered for the study were water turbidity, pH, conductivity, color and dissolved solids, with the average temperature 10°C and a flow rate of 148 liters per second. The dose given coagulant by jar testing was optimized using neural networks with three specific topologies, was concluded that the topology more adequate is the generalized regression with a Assertiveness of 96.9 per cent compared to the actual data and its color, turbidity and pH, in that order: training a 98.4 per cent linear correlation of being able to show that the most influential factors according to their impact level are variables obtained. The application of this alternative allows cost savings and improve water quality in less time than the classic methods of calculation.

Keywords: neural network, water, optimization, coagulant (Al_2SO_4)

I. INTRODUCCIÓN

La ciudad de Huancayo cuenta con una planta de tratamiento de agua potable administrada por la Empresa de Servicios de Agua Potable y Alcantarillado Municipal de Huancayo (SEDAM HUANCAYO S.A). Esta planta tiene dos circuitos que abastecen de agua potable aproximadamente a un 80 por ciento de la ciudad que tiene una población de aproximada de 364 010 habitantes (INEI, 2014) y está ubicado en la región Junín, Perú entre las coordenadas geográficas de 12°00'00" Sur y 75°11'00" Oeste, con una altitud de 3 420 m.

La planta de tratamiento de agua potable mencionada tiene una capacidad total promedio de procesamiento máximo de 500 l/s. Los parámetros físicos y químicos del agua al ingreso a esta planta para su tratamiento no son estables, debido a las precipitaciones que ocurren durante los meses de octubre a marzo, esto hace que se altere de manera abrupta la concentración de sólidos suspendidos totales presentes en ella.

En el proceso de tratamiento de agua potable, la coagulación es la operación más importante para la eliminación de impurezas, especialmente para la precipitación de los sólidos suspendidos presentes en el agua que se encuentran como partículas coloidales, por lo que, el cálculo de la dosis óptima de coagulante es complejo y está influenciado por factores como el corto tiempo de reacción del proceso de coagulación, el largo tiempo de reacción del proceso de floculación y el caudal de agua que ingresa al tratamiento.

El costo del coagulante varía de acuerdo a la dosis empleada y al tipo de coagulante, por lo que la sobredosis afectará a los costos de operación de la empresa.

Para el cálculo de la dosis óptima de coagulante se requiere de un prueba de laboratorio basada en operaciones y procesos denominada *Prueba de Jarras*, una vez determinado la cantidad de coagulante se requiere la ayuda de un supervisor, quien debe realizar los ajustes necesarios al dosificador respectivo en el circuito de la planta de forma manual con el fin de

garantizar la remoción de turbiedad efectiva del agua tratada, ocasionando que este proceso consume demasiado tiempo en su ejecución.

Para la potabilización del agua en la planta de SEDAM Huancayo el tratamiento mencionado utiliza como coagulante al sulfato de aluminio TIPO B granulado, para remover la materia coloidal y sustancias orgánicas. La sobre dosis de coagulante hace que se incrementen los costos y conlleva a producir elevadas concentraciones de aluminio residual en el agua potable y que pueden tener implicaciones perjudiciales para la salud humana. Estudios realizados indican que la presencia de aluminio en concentraciones mayores que 0,1–0,2 mg/l suele ocasionar quejas de los consumidores como consecuencia de la precipitación del flocúlos de hidróxido de aluminio en los sistemas de distribución y la alteración de la coloración del agua. Por lo cual, es importante optimizar los procesos de tratamiento con el fin de reducir al mínimo la presencia de residuos de aluminio en el sistema de abastecimiento. (World Health Organization, 2013)

El agua es uno de los elementos más importantes para el logro de algunos indicadores de desarrollo como la nutrición, salud e incluso educación, por lo cual es importante articular acciones para mejorar su tratamiento en la solución de problemas de la población y sectores más pobres del país. La cobertura de agua potable y saneamiento en el Perú hasta el 2011 fue de 77 y 66 por ciento, siendo este índice muy debajo al promedio de los países de América Latina. (Autoridad Nacional del Agua, 2013). Se han realizado muchos estudios en el tratamiento de agua potable para consumo humano, como por ejemplo en el Centro de Consulta del Agua (IMTA, México, 2011), Centro Panamericano de Ingeniería Sanitaria y Ciencias el Ambiente (CEPIS) e Internacional Water and Sanitation Centre (IRC, Holanda), donde se han generado métodos de tratamiento de agua en base a tecnologías modernas. Según los estudios para el tratamiento de agua ésta debe de ser sometida a su potabilización, en el cual el agua no debe de contener contaminantes químicos, agentes químicos o agentes infecciosos que afecten a la salud humana. Los criterios estéticos y no sanitarios que también se deberían remover del agua son los sólidos suspendidos y la materia orgánica natural.

Los modelos de Red Neurona Artificial (RNA) son funciones-aproximadoras altamente flexibles que han demostrado su utilidad en una amplia gama de aplicaciones del recurso hídrico. Muchos estudios han demostrado que las redes neuronales se desempeñan mejor que muchos de los métodos de modelación clásicos (Zhang *et al.*, 2002). Las RNA

representan una tecnología inteligente muy importante que utiliza el conocimiento experimental para razonar y resolver problemas específicos de manera análoga al funcionamiento del cerebro humano, el conocimiento es obtenido por la RNA a través de un proceso de aprendizaje y las conexiones interneuronales conocidas como pesos sinápticos son utilizadas para almacenar dicho conocimiento. Un algoritmo de RNA puede llegar al resultado en condición de escasez de datos con la ayuda de la información actual, aceptar la entrada continua de datos, entrenarse y recordar. La mayor ventaja de una red neuronal es su habilidad para relacionar modelos complejos no-lineales sin suposiciones a priori de la naturaleza de la relación. (Durdu, 2009).

1.1. Diagnóstico del recurso hídrico.

Los recursos hídricos que utiliza la planta de tratamiento en la ciudad de Huancayo, son provenientes de la subcuenca del río Shullcas, teniendo las siguientes características:

1.1.1. Ubicación geográfica

La subcuenca del río Shullcas, se encuentra ubicada en el ámbito de los distritos de Huancayo, Chilca, Huancán y El Tambo Provincia de Huancayo, Región de Junín. Es uno de los afluentes del río Mantaro en su margen izquierda y limitado entre las coordenadas geográficas $11^{\circ} 52' 13''$ a $12^{\circ} 07' 00''$ de Latitud Sur y entre los meridianos $75^{\circ} 01' 57''$ a $75^{\circ} 14' 37''$ de Longitud Oeste. Está asociada al nevado Huaytapallana y se encuentra ubicada en la margen izquierda del río Mantaro. (Superintendencia Nacional de Servicios de Saneamiento, 2014).

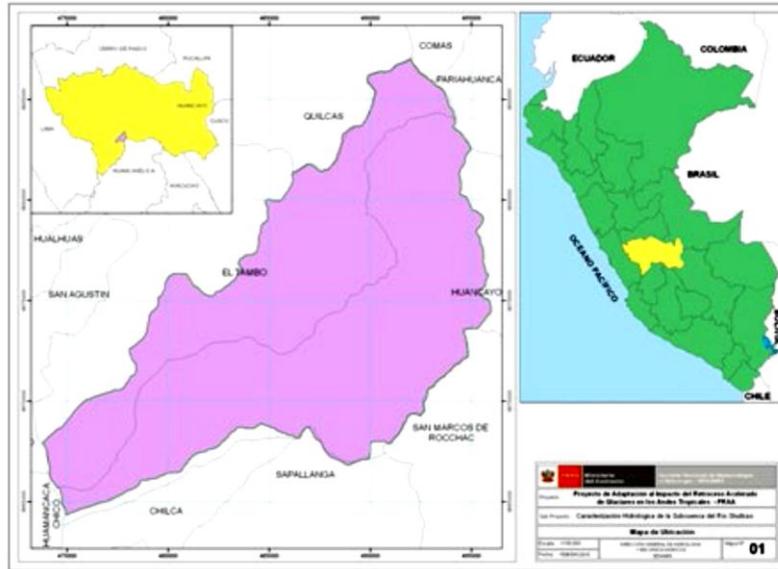


Figura 1: Ubicación de la Sub cuenca del Río Shullcas
 FUENTE: SUNASS (2014)

1.1.2. Hidrografía

El río Shullcas es tributario del río Mantaro con un caudal promedio durante la época de avenida de $5,0 \text{ m}^3/\text{s}$ y en estiaje el caudal desciende hasta $1,5 \text{ m}^3/\text{s}$. Durante su recorrido, el río alcanza una longitud aproximada de 35,9 km, un ancho promedio de 4 a 5 m y una pendiente de 7,5 por ciento con un desnivel de 2000 m en 15 km.

El río Shullcas es de régimen lacustre, alimentado por los desagües de las lagunas Chuspicocha y Lazuntay y esta a su vez por la fusión del hielo glaciar del nevado Huaytapallana, de allí que el caudal es permanente.

En la figura 2 se muestra la red Hidrográfica del río Shullcas que evidencia el origen en los glaciares del Huaytapallana a una altitud de 5 557 m.

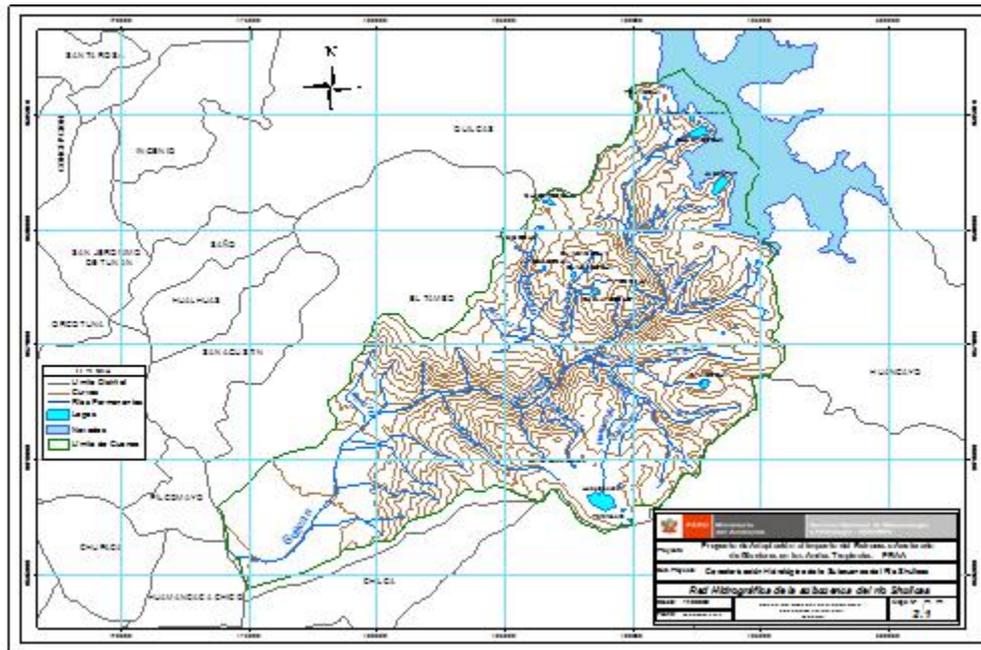


Figura 2: Mapa de la Red Hidrográfica de la subcuenca del río Shullcas
FUENTE: MINAM (2013)

1.2. Fuente y captación de agua para la planta de tratamiento.

La planta de tratamiento de la ciudad de Huancayo utiliza los recursos hídricos superficiales provenientes del río Shullcas.

1.2.1. Captaciones de agua para la planta de tratamiento

La principal captación de agua superficial por parte de la empresa SEDAM Huancayo S.A esta ubicada en el lugar denominado Chamiseria a 5 km aguas arriba de la planta, de la cual se capta entre 350 a 500 l/s. En la figura 3 se muestra la captación del agua.



Figura 3: Captación de agua para la Planta en Chamisería

FUENTE: SUNASS (2014)

1.3. Planta de tratamiento de agua potable.

La Planta de Tratamiento de Agua está ubicada en el anexo de Vilcacoto, del distrito de Huancayo, con un área de 7902 m². Hay dos circuitos de tratamiento: la antigua (I), de 60 años de antigüedad, y la planta nueva (II), operándose desde el año 2008. Así mismo, cuenta con un laboratorio donde se realizan los análisis físico, químico y microbiológico del agua, un almacén de insumos químicos, un sistema de dosificación de insumos químicos. (Superintendencia Nacional de Servicios de Saneamiento, 2014).

a. Circuito de tratamiento de agua N°1.

La planta de tratamiento de agua N° 1 es del tipo convencional. Actualmente sólo puede tratar entre 120 - 150 l/s (según las condiciones de la calidad de agua captada).

b. Circuito de tratamiento de agua N°2 (planta nueva y la del estudio).

Este circuito es de tecnología tipo CEPIS (Centro Panamericano de Ingeniería Sanitaria), y opera desde el mes de agosto del 2008 a la fecha. Trabaja con una máxima capacidad de 400 l/s dependiendo de las características del agua captada.

En la figura 4 se muestra la Planta de Tratamiento de Agua Potable de Vilcacoto que tiene una capacidad de procesamiento máximo de 500 l/s en total



Figura 4: Planta de tratamiento de agua de Vilcacoto
FUENTE: SUNASS (2014)

1.4. Procesos de tratamiento de agua potable en Huancayo

El tratamiento de agua potable tiene los siguientes procesos que se describen a continuación:

- **Captación.** Es la cantidad necesaria de agua del río que es derivada a las instalaciones para su tratamiento, pasando a través de un sistema de rejas que retiene los sólidos de arrastre en suspensión.
- **Desarenadores.** Es una estructura hidráulica que tiene como función sedimentar las partículas de arena del agua captada a fin de evitar que ingresen a la línea de conducción para el proceso de tratamiento.
- **Pre cloración.** Es un procedimiento con el objeto de disminuir el contenido de materia orgánica y disminuir los niveles de contaminación.
- **Mezcla rápida.** Es una unidad de coagulante química (sulfato de aluminio) que se adiciona al agua cruda, con este proceso se inicia el tratamiento del agua.

- **Floculación.** Es un proceso químico mediante el cual, con la adición de sustancias denominadas floculantes, se aglutinan las sustancias coloidales presentes en el agua, facilitando de esta forma su decantación y posterior filtrado.
- **Decantación.** Es la separación de los flocs, que precipitan en el fondo de la superficie por acción de la gravedad generando una sedimentación.
- **Filtración.** Es la eliminación de los microorganismos mediante el uso de filtros utilizando un medio filtrante.
- **Cloración.** Es un procedimiento de desinfección del agua mediante el empleo de cloro o compuestos clorados. Se puede emplear gas cloro, pero normalmente se emplea hipoclorito de sodio por su mayor facilidad de almacenamiento y dosificación.

1.5. Alcance de la investigación

La investigación de nivel descriptivo relacional, predictivo del tipo aplicativo y de naturaleza cuantitativa ya que evalúa y predice la cantidad óptima de coagulante que se utilizará en el tratamiento de agua potable para la ciudad de Huancayo, utilizando tres modelos de redes neuronales artificiales con topologías particulares a partir de datos obtenidos con la *Prueba de Jarras* en un lapso de once meses con muestreo aleatorio diario de agua al ingreso y salida de la planta de tratamiento, considerando seis factores físicos y químicos críticos. Los parámetros de calidad de agua producida están por debajo de los límites permisibles establecidas por el Ministerio de Salud.

La hipótesis planteada fue: La aplicación de redes neuronales artificiales basada en los datos obtenidos de la *Prueba de Jarras*, permite optimizar, controlar y predecir la dosificación de coagulante en el tratamiento de agua potable de la empresa SEDAM Huancayo.

1.6. Objetivo de la investigación.

Optimizar, controlar y predecir la dosificación de coagulante en el tratamiento de agua potable de la Empresa SEDAM HUANCAYO a través de redes neuronales artificiales (RNA) entrenada y validada, utilizando los datos obtenidos de la *Prueba de Jarras* durante 11 meses.

II. REVISIÓN DE LA LITERATURA

2.1. Antecedentes de la investigación.

Valentin y Denoeuxb (2000), informan sobre resultados de la aplicación con técnicas de la Red Neuronal Artificial en el control de la coagulación en el agua potable en plantas de tratamiento. El proceso de la coagulación implica muchos fenómenos físicos y químicos complejos que son difíciles de modelar utilizando métodos tradicionales. Se ha demostrado que la cantidad de coagulante que asegura la eficacia de tratamiento óptima experimentalmente no está linealmente correlacionado a características acuáticas crudas como turbidez, conductividad, pH, temperatura, etc. Una característica clave del sistema desarrollado es su capacidad de tomar decisiones considerando varias fuentes de incertidumbre, como datos de entrada atípicos, errores de medida y contenido de información limitado del juego de formación.

Heddam *et al.* (2011), realizaron un estudio en la Planta de tratamiento de agua en Boudouaou, Argelia, proponiendo dos modelos de redes neuronales; el primero el modelo de redes neuronales de regresión generalizada (GRNN) y el modelo radial de redes neuronales (RNFBR), los cuales fueron sometidos a pruebas con datos divididos en tres grupos: para el entrenamiento, la validación y la prueba, cuyos resultados obtenidos nos afirman que el mejor modelo fue el modelo de GRNN el cual presenta los mejores resultados.

Griffiths (2011), examinó la viabilidad de aplicar las redes neuronales artificiales (RNAs) para la filtración y la optimización en términos de partícula de la post filtración. Los modelos de proceso fueron desarrollados con éxito para tres temporadas separadas (verano, invierno y primavera) para predecir la post filtración de la partícula se cuenta con tres variedades de tamaño diferentes: 3–5, 5–10, y 10–25 μm . Los modelos de proceso inverso fueron desarrollados para predecir la turbiedad acuática requerida y para alcanzar los niveles del tamaño de las partículas adecuadas.

Aviles y Tirado (2010), afirman que la dosis de coagulante es tan importante para el proceso de tratamiento de agua. Se utiliza para aglomerar sólidos suspendidos en cuerpos más grandes. Estos productos químicos coagulantes se agregan al agua para facilitar la adhesión entre las partículas presentes y se utilizan para mejorar la extracción partículas coloidales y sustancias disueltas. La optimización de la coagulación es importante para seleccionar mejor su dosificación, ya que demasiado coagulante lleva a la sobredosificación lo cual conduce a un mayor costo del tratamiento y las preocupaciones para la salud de la población. Una dosis óptima de coagulante en el tratamiento del agua se evalúa generalmente por la *Prueba de Jarras* realizado experimentalmente para determinar la cantidad de coagulación. Esta Prueba requiere de mucho tiempo y están sujetas a variaciones en sus observaciones. Por otra parte, realizar a menudo Pruebas de Jarras consume gran cantidad de productos químicos para su análisis, y también requiere experiencia para obtener buenos resultados a la hora de determinar la dosis de coagulante.

Badalians *et al.* (2011). Han realizado estudios usando la Red Neuronal Artificial (RNA) para predecir la coagulación/floculación de sólidos suspendidos en planta de tratamiento de agua, en el cual se han utilizado cinco tipos de poli cloruro de aluminio (PAC) como coagulante utilizados para examinar los efectos de cada uno de ellos aplicados en la extracción de sólidos en suspensión. La determinación de la dosis óptima de coagulante es vital, si hubiera una dosificación insuficiente se tendría resultados no deseables en la calidad del agua. Tradicionalmente, la Pruebas de Jarras y la experiencia de los operadores se utilizan para determinar la dosis de coagulante. Pero este método es costoso y lleva mucho tiempo y no permite dar respuestas a los cambios de calidad del agua pura en tiempo real. Actualmente, el modelo de redes neuronales artificiales (RNA) se ha venido aplicado cada vez más en los problemas de medio ambiente y recursos hídricos. Los resultados de los modelos tiene un valor de correlación muy elevado, los cuales varían entre 0,90 a 0,98 para el proceso de predicción de turbiedad del agua. Por lo tanto, el modelo de simulación de redes neuronales artificiales (RNA) permite a los operadores obtener tiempo real la dosis de poli cloruro de aluminio de manera fácil.

Saint-Gerons (2004) Indica que el oxígeno disuelto constituye una variable fundamental en la evaluación de la calidad del agua de los ríos, ya que determina la diversidad de organismos presentes en su seno. Para monitorear su valor, se ha desarrollado un sensor software haciendo uso de la técnica de redes neuronales. La red neuronal elegida es de tipo

backpropagation, con una arquitectura sigmoideal/lineal de dos capas, que utiliza como entradas tres variables medibles: temperatura, turbidez y potencial redox. La solución propuesta se ha mostrado idónea en términos de error de estimación, complejidad y entradas necesarias. La red permite además, reducir costes en instrumentación, al ser los datos requeridos como entradas deducibles en una estación depuradora de agua residual (E.D.A.R.). Las pruebas de validación, realizadas sobre datos tomados de las estaciones medioambientales de Navarra, demuestran la efectividad de la solución propuesta.

Tezel *et al.* (2009), señalan que una red neuronal artificial (RNA) es el modelo introducido y aplicado a un estudio de caso de una planta de tratamiento de agua residual doméstica. El modelo utiliza las funciones de entrada y salida de cada uno de los procesos de la planta de tratamiento en su conjunto, así como salidas separadas de cada unidad de tratamiento. Los estudios del modelado de la planta de tratamiento de agua se centraron en las variables individuales de modo que este estudio divide la planta de tratamiento en dos partes, el tratamiento primario y tratamiento biológico. Las variables en la primera parte son el pH, caudal, sólidos en suspensión, Demanda Bioquímica de Oxígeno (DBO) y Demanda Química de Oxígeno (DQO) en la segunda parte, además de nitrógeno y los compuestos de fósforo la red neuronal se aplicó en las dos partes de forma consecutiva, y la salida de la primera parte se definió como la entrada de la segunda parte. El modelo desarrollado en dos fases es capaz de representar adecuadamente el comportamiento del sistema de tratamiento.

2.2. El proceso de coagulación

El proceso de coagulación se ejecuta al inicio del circuito de tratamiento para agua potable como podemos observar en la figura 5 presentada:

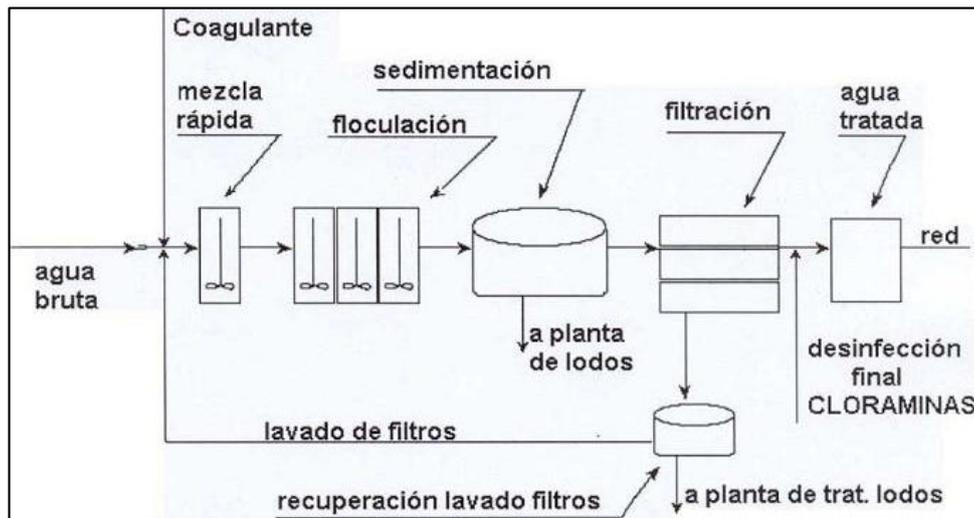


Figura 5: Esquema de procesamiento de agua potable.

FUENTE: El agua potable. (2014).

La coagulación es un proceso de desestabilización de las cargas eléctricas en las partículas coloidales presentes en el agua de entrada a la planta, ésta se produce al neutralizar las fuerzas que mantienen separados a las partículas, por medio de la adición de sustancias químicas (coagulantes) y la aplicación de energía para lograr el mezclado correspondiente.

La coagulación es el tratamiento más eficaz para precipitar impurezas del agua en forma de flocs que luego sedimentan en el fondo de las pozas de sedimentación. Este proceso cuando no se realiza adecuadamente resulta muy costoso; asimismo, se conoce como un método universal para precipitar impurezas en el agua con la adición de un coagulante que permite eliminar una gran cantidad de sustancias de diversa naturaleza que son eliminados al menor costo, en comparación con otros métodos. (CEPIS, 2004)

La dosis del coagulante condiciona el funcionamiento de las unidades de decantación y que ayuda a una eficiente clarificación. Los coloides son suspensiones estables, por lo que es imposible su sedimentación natural y son sustancias responsables de la turbiedad y del color del agua. El esquema básico se muestra en la figura 6.

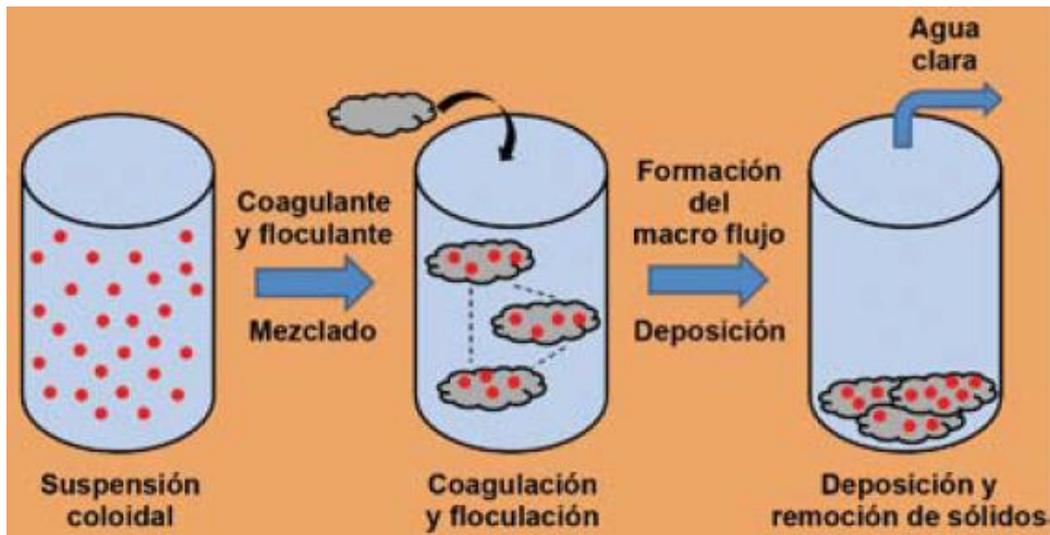


Figura 6: Proceso de coagulación.

FUENTE: Wilson (2013)

Teniendo en cuenta el gran consumo de coagulante que se necesita en una planta de tratamiento de agua, muchos investigadores han estudiado formas para reducir los costos mediante la optimización en la dosificación de coagulante y para esto han recurrido al uso de la tecnología.

La complejidad existente entre la dosis de coagulante requerida en función de los parámetros de calidad de agua cruda, y la influencia de factores tales como: el corto tiempo de reacción del proceso de coagulación, el tiempo prolongado de reacción del proceso de floculación y el caudal de agua tratada, hacen que el control de este proceso requiera de técnicas de apoyo como la *Prueba de Jarras* en la estimación de la dosis óptima y de la acción de un operador que supervise el proceso y haga los ajustes necesarios en el circuito para garantizar una remoción de turbiedad efectiva.

En la actualidad existen algunos sistemas comerciales para el control del proceso de coagulación tales como el *streaming current detector*, el cual ha demostrado resultados positivos en plantas de tratamiento con calidades de agua cruda poco variables, mostrando también su incapacidad para adaptarse a todos los tipos de calidad de agua cruda.

El mejoramiento en el control de los procesos mediante la introducción de nuevas técnicas tales como las redes neuronales y la lógica difusa, abre una nueva ventana hacia el desarrollo

de soluciones óptimas, para procesos cuyo control mediante el uso de técnicas convencionales resulta muy complejo.

2.3. Fundamentos teóricos para la investigación

A continuación se expone los fundamentos teóricos acerca de la coagulación de partículas en suspensión en el tratamiento de agua, asimismo los principios matemáticos y principios que rigen a las redes neuronales artificiales.

2.3.1. Coagulación.

(Amirtharajah, 1989) y (Cohen y Hannah, 1971) proponen los mecanismos de coagulación que se describen a continuación.

En la figura 7 que sigue se muestra como las sustancias químicas anulan las cargas eléctricas de la superficie del coloide permitiendo que las partículas coloidales se aglomeren formando flóculos.

Los sistemas coloidales presentan una superficie de contacto inmensa entre la fase sólida y la fase líquida, por ejemplo un cubo de un centímetro cubico, tiene una superficie total de seis cm^2 ; si está dividido en pequeños cubos elementales, la superficie total de todos aquellos es mucho más grande.

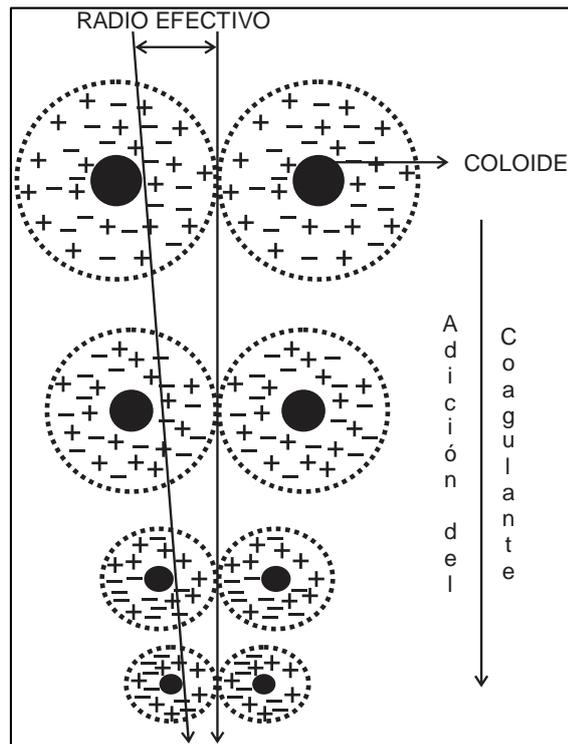


Figura 7: Anulación de cargas eléctricas en la superficie del coloide.

FUENTE: CEPIS (2004)

2.3.2. Mecanismo de la coagulación

El mecanismo de coagulación se puede obtener por procedimientos fisicoquímicos siguientes:

a. Compresión de la doble capa

Se define cuando se aproximan dos partículas semejantes y sus capas difusas interactúan generando una fuerza de repulsión, cuyo potencial de repulsión está en función de la distancia que los separa y cae rápidamente con el incremento de iones de carga opuesta al de las partículas, esto se consigue sólo con los iones del coagulante.

Por otro lado, existe un potencial de atracción o fuerzas de atracción E_a , entre las partículas llamadas fuerzas de Van der Waals (figura 8), que dependen de los átomos que constituyen las partículas y de la densidad de estos últimos. Contrariamente a las Fuerzas

de repulsión, las fuerzas de Van der Waals no son afectados por las características de la solución.

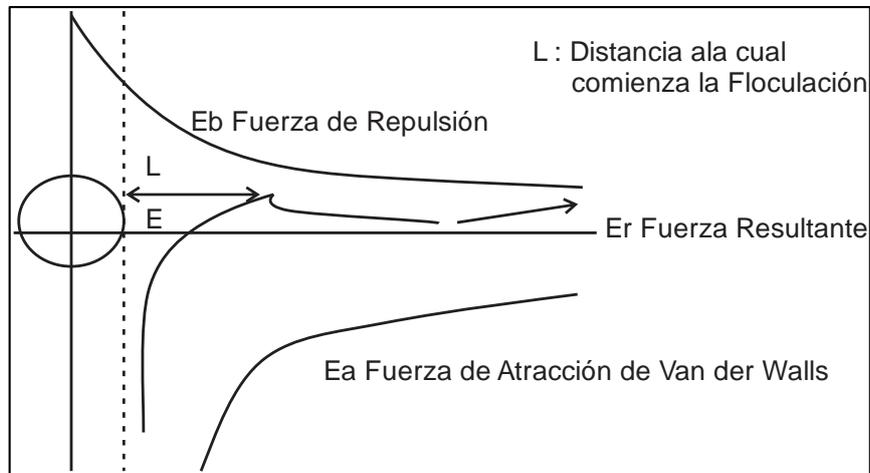


Figura 8: Fuerzas de Van der Waals

FUENTE: CEPIS (2004)

b. Absorción y neutralización de cargas

Las partículas coloidales poseen carga negativa en su superficie, estas cargas llamadas primarias atraen los iones positivos que se encuentran en solución dentro del agua y forman la primera capa adherida al coloide.

Después de la teoría de la doble capa, la coagulación es la considerada como la anulación del potencial obtenido por adición de productos de coagulación -floculación, en la que la fuerza natural de mezcla debido al movimiento browniano no es suficiente, requiriéndose una energía complementaria necesaria; por ejemplo realizar la agitación mecánica o hidráulica.

Cuando se adiciona un exceso de coagulante al agua a tratar, se produce la reestabilización de la carga de la partícula, esto se puede explicar debido a que el exceso de coagulantes es absorbido en la superficie de la partícula, produciendo una carga invertida a la carga original.

c. Atrapamiento de partículas dentro de un precipitado

Las partículas coloidales desestabilizadas, se pueden atrapar dentro de un floc, cuando se adiciona una cantidad suficiente de coagulantes, generalmente sales de metales trivalente como el sulfato de aluminio $Al_2(SO_4)_3$, o Cloruro Férrico $FeCl_3$, el floc está formado de moléculas de $Al(OH)_3$ o de $Fe(OH)_3$. La presencia de ciertos aniones y partículas coloidales acelera la formación del precipitado. Estas partículas coloidales forman los anillos durante el proceso de formación del floc; este fenómeno puede tener una relación inversa entre la turbiedad y la cantidad de coagulante requerida. En términos generales se puede afirmar que una concentración importante de partículas en suspensión puede requerir menor cantidad de coagulante. En la figura N° 9 se muestra el proceso de atrapamiento de partículas dentro de un floc.

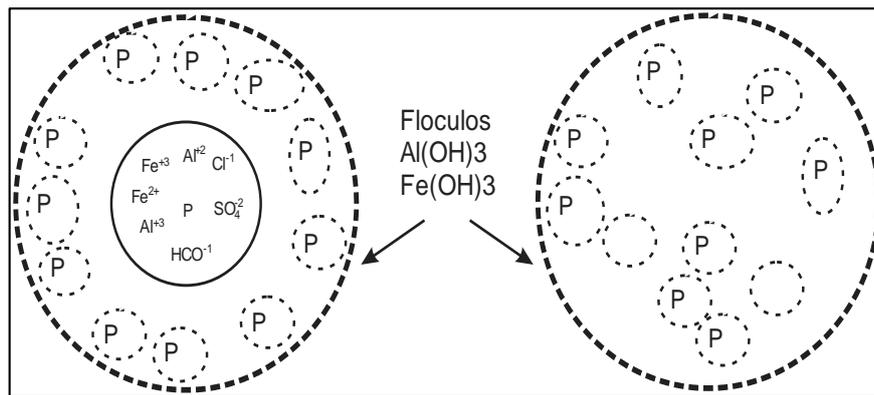


Figura 9: Atrapamiento de las partículas en un floc

FUENTE: CEPIS (2004)

d. Adsorción y puente

Una de las formas de ahorrar costos en el tratamiento de agua, es utilizando un polímero aniónico, cuando las partículas están cargadas negativamente. Este fenómeno es explicado por la *Teoría del Puente*, en el cual las moléculas de los polímeros muy largas contienen grupos químicos que podrían absorber las partículas coloidales. Sin embargo, la molécula del polímero puede absorber una partícula coloidal en una de sus

extremidades, mientras que los otros lugares son libres para poder absorber otras partículas.

Por eso se dice, que las moléculas de los polímeros forman el *puente* entre las partículas de los coloidales, esto podría ocasionar una reestabilización de la suspensión, por una excesiva carga en los polímeros, según la figura 10.

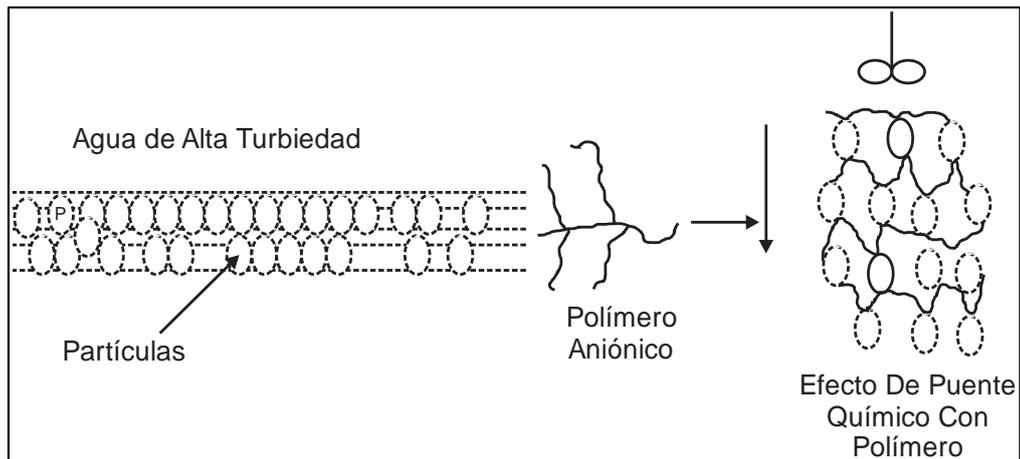


Figura 10: Efecto de puente de las partículas en suspensión

FUENTE: CEPIS (2004)

e. Coagulantes utilizados

Los coagulantes son productos químicos que al adicionar al agua son capaces de producir una reacción química con los elementos químicos del agua, especialmente con la alcalinidad del agua para formar un precipitado voluminoso, muy absorbente, constituido generalmente por el hidróxido metálico del coagulante que se está utilizando.

Los principales coagulantes utilizados para desestabilizar las partículas y producir el floc son:

- Sulfato de Aluminio.
- Aluminato de Sodio.
- Cloruro de Aluminio.
- Cloruro Férrico.
- Sulfato Férrico.

- Sulfato Ferroso.
- Polielectrolitos (Como ayudantes de floculación).

Siendo los más utilizados las sales de Aluminio y de Hierro; cuando se adiciona estas sales al agua se producen una serie de reacciones muy complejas donde los productos de hidrólisis son más eficaces que los iones mismos; estas sales reaccionan con la alcalinidad del agua y producen los Hidróxidos de Aluminio o Hierro que son insolubles y forman los precipitados.

2.3.3. Remoción de turbiedad

La aplicación de una dosis creciente del coagulante al agua presenta diferentes zonas de coagulación en la cámara respectiva, como se puede observar en la figura 11, donde cada una de las zonas está definida por:

Zona I. La dosis de coagulante no es suficiente para desestabilizar las partículas y por lo tanto no se produce coagulación.

Zona II. Al incrementar la dosis de coagulantes, se produce una rápida aglutinación de los coloides.

Zona III. Si se continúa incrementando la dosis, llega un momento en que no se produce una buena coagulación, ya que los coloides se re estabilizan.

Zona IV. Al aumentar aún más la dosis, hasta producir una súper saturación se produce de nuevo una rápida precipitación de los coagulantes que hace un efecto de barrido, arrastrando en su descenso las partículas que conforman la turbiedad.

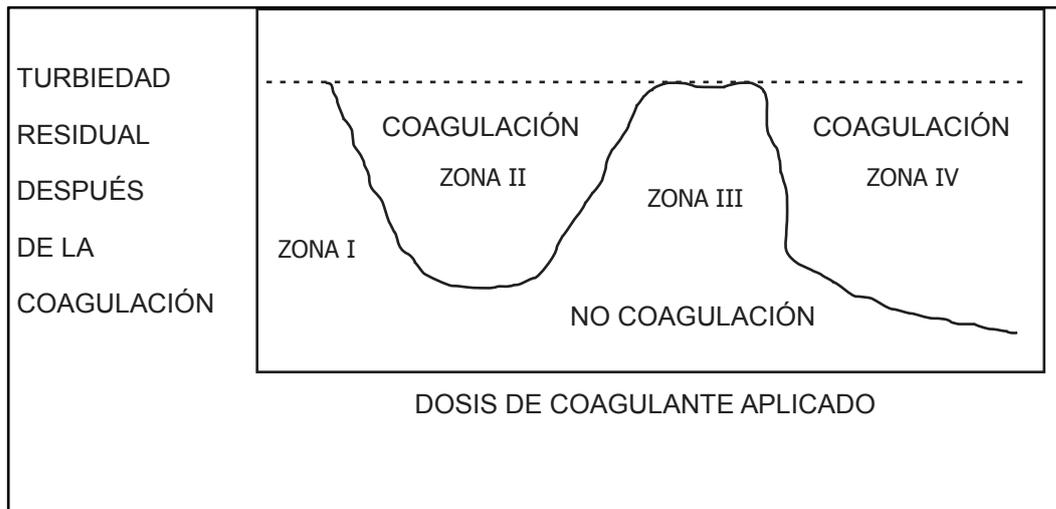


Figura 11: Diagrama de Remoción de Turbiedad

FUENTE: CEPIS (2004)

2.3.4. Factores que influyen en la coagulación

Los factores que influyen en el proceso de coagulación son:

- pH
- Turbiedad.
- Sales disueltas.
- Temperatura del agua.
- Tipo de coagulante utilizado.
- Condiciones de Mezcla.
- Sistemas de aplicación de los coagulantes.
- Tipos de mezcla y el color.

La interrelación entre cada uno de ellos permiten predecir cuáles son las cantidades de los coagulantes que se debe de adicionar al agua.

a. Influencia del pH

El pH es una medida de la actividad del ion hidrógeno en una solución, y se expresa matemáticamente mediante la siguiente relación:

$$pH = -\log\{H_3O^+\}$$

El pH es la variable más importante que se debe considerarse en el momento de la coagulación, porque para cada tipo de agua existe un rango de pH óptimo en el cual la coagulación se realiza a mayor y menor velocidad.

El rango de *pH* está en función al tipo de coagulante que es utilizado y a la naturaleza del agua que se quiera tratar; si la coagulación se realiza fuera del rango de *pH* óptimo entonces se debe aumentar la cantidad del coagulante; por lo tanto la dosis requerida es alta.

Por ejemplo, para sales de aluminio el rango de *pH* para la coagulación es de 6,5 a 8,0 y para las sales de hierro, el rango de *pH* óptimo es de 5,5 a 8,5 unidades.

b. Influencia de las sales disueltas

Las sales contenidas en el agua ejercen influencias sobre la coagulación y floculación:

- Modificación del rango de pH óptimo.
- Modificación del tiempo requerido para la floculación.
- Modificación de la cantidad de coagulantes requeridos.
- Modificación de la cantidad residual del coagulante dentro del efluente.

c. Influencia de la temperatura del agua

La variación de un grado centígrado de temperatura en el agua genera variaciones en su densidad; si fueran diferentes grados de temperatura afecta a la energía cinética de las partículas en suspensión, por lo que, la coagulación se hace más lenta a temperaturas elevadas. Sin embargo, la disminución de la temperatura del agua en una unidad de decantación conlleva a un aumento de su viscosidad; esto explica las dificultades de la sedimentación de un floc.

d. Influencia de la dosis del coagulante

La cantidad de coagulante a utilizar influye directamente en la eficiencia de la coagulación, así:

- La poca cantidad del coagulante, no neutraliza totalmente la carga de la partícula, generando escasa formación de los microfloculos, por lo tanto, la turbiedad residual se elevada.
- La alta cantidad de coagulante produce la inversión de la carga de la partícula, conduciendo a la formación de gran cantidad de microfloculos con tamaños muy pequeños cuyas velocidades de sedimentación son muy bajas, por lo tanto, la turbiedad residual es elevada.
- La selección del coagulante y la cantidad óptima de su aplicación; se determina mediante los ensayos denominado *Pruebas de Jarra*.
- La selección del coagulante y la dosis juegan un rol muy importante sobre: La buena o mala calidad del agua clarificada y el buen o mal funcionamiento de los decantadores.

e. Influencia del tipo de mezcla

El grado de agitación que se da en la masa de agua durante la adición del coagulante, determina si la coagulación es completa; la formación de turbulencias desiguales hacen que cierta porción de agua tenga mayor concentración de coagulantes y en la otra parte tenga poco o casi nada; por lo que, la agitación debe ser uniforme e intensa en toda la masa de agua, para asegurar la mezcla correcta entre el agua y el coagulante y que se haya producido la reacción química de neutralización de las cargas correspondiente.

En el transcurso de la coagulación y floculación, se produce mezcla de productos químicos en dos etapas. En la primera etapa; la mezcla es enérgica y de corta duración (60 segundos como máximo) llamado mezcla rápida, esta mezcla tiene por objeto dispersar la totalidad del coagulante dentro del volumen del agua a tratar, y en la segunda etapa; la mezcla es lenta y tiene por objeto desarrollar los microfloculos.

La mezcla rápida se efectúa por la inyección de productos químicos dentro de la zona de turbulencia fuerte, si se produjera una inadecuada mezcla rápida, esto conllevaría a un incremento de productos químicos.

Tipos de mezcla

Los tipos de mezclas que se podrían generar se describen a continuación:

- **Mezcladores Mecánicos:** En este tipo de mezcladores mecánicos se tiene a los retromezcladores más conocidos como los agitadores.
- **Mezcladores Hidráulicos:** En este tipo de mezcladores se tiene los de Resalto Hidráulico entre ellos tenemos: Canaleta Parshall y Vertedero rectangular.
- En línea: Los mezcladores de línea son los difusores que son las tuberías y canales, así mismo, se tiene los inyectores, etc.

f. Influencia de la turbiedad

La turbiedad es una forma indirecta de medir la concentración de las partículas suspendidas en un líquido. Esta mide el efecto de la dispersión de las partículas que se presentan al paso de la luz y está en función del número, tamaño y forma de partículas.

La turbiedad del agua superficial, se debe en gran parte a las partículas de lodos de sílice de diámetro que varían entre 0,2 a 5 μm . La coagulación de estas partículas es muy fácil de realizar cuando el pH se mantiene dentro del rango óptimo. Esta variación de la concentración de las partículas permite hacer las siguientes predicciones:

- Si para cada turbiedad existe una cantidad de coagulante, con el que se obtiene la turbiedad residual más baja, está corresponde a la dosis óptima.
- Si la turbiedad aumenta se debe adicionar una cierta cantidad de coagulante debido a la probabilidad de colisión entre las partículas es muy elevada por lo que, facilita la coagulación con mayor rapidez. Muy por lo contrario, cuando la turbiedad es baja la coagulación se realiza muy lenta, por lo que la cantidad del coagulante debe ser igual o mayor que cuando la turbiedad es alta.
- Cuando la turbidez es muy alta conviene realizar la pre sedimentación natural o forzada, en este caso se emplea un polímero aniónico. (Por ejemplo, en la Planta de la Atarjea, se realiza un tratamiento con polímero aniónico en época de alta turbiedad).
- Es siempre más fácil coagular aguas que tienen baja turbiedad, que aquellas que estén contaminadas por desagües domésticos industriales, porque requieren mayor cantidad de coagulante que los no contaminados.

2.3.5. Condiciones para una buena reacción del coagulante

Se considera una reacción adecuada entre el coagulante y el agua cuando se cumple las siguientes condiciones:

- a) La dosis del coagulante que se adicione al agua sea en forma constante y uniforme en la unidad de mezcla rápida, tal que, el coagulante sea completamente dispersado y mezclado con el agua.
- b) El sistema de dosificación proporcione un caudal constante y fácilmente regulable, tal como se muestra en la figura 12, en el que las condiciones de mezcla del coagulante con el agua cae en su totalidad a la masa de agua. Esta condición se obtiene por medio de los equipos de dosificación, tanto para los coagulantes en el estado sólido y en el estado líquido, los que deben de encontrarse calibrados y comprobados por medio de las pruebas de aforamiento.

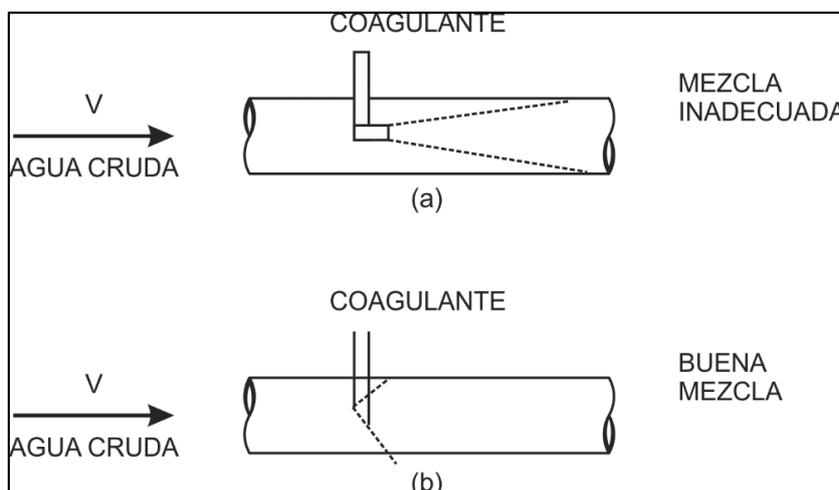


Figura 12: Condiciones de Mezcla

FUENTE: CEPIS (2004)

2.3.6. Tipos de coagulación

Se presentan dos tipos básicos de coagulación: por Adsorción y por Barrido.

- a) **Coagulación por adsorción.-** Se presenta cuando el agua tiene una alta concentración de partículas al estado coloidal; cuando el coagulante es adicionado al agua turbia los productos solubles de los coagulantes son absorbidas por los coloides y forman los flóculos en forma casi instantánea. (Figura 13).

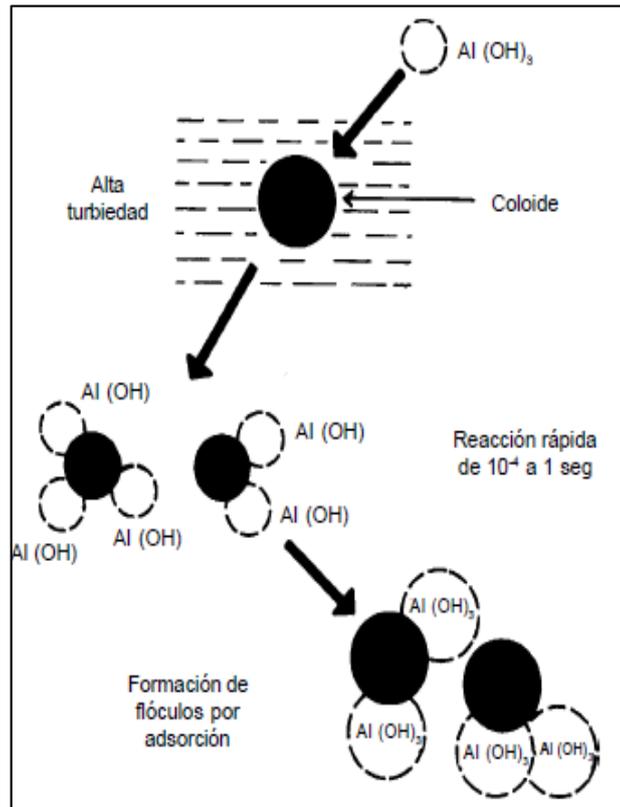


Figura 13: Coagulación por Adsorción

.FUENTE: CEPIS (2004)

- b) Coagulación por barrido.-** Este tipo de coagulación se presenta cuando el agua es clara (baja turbiedad) y que la cantidad de partículas coloides es pequeña; en este caso las partículas son entrampadas al producirse una sobresaturación de precipitado de sulfato de aluminio o cloruro férrico. (Figura 14).

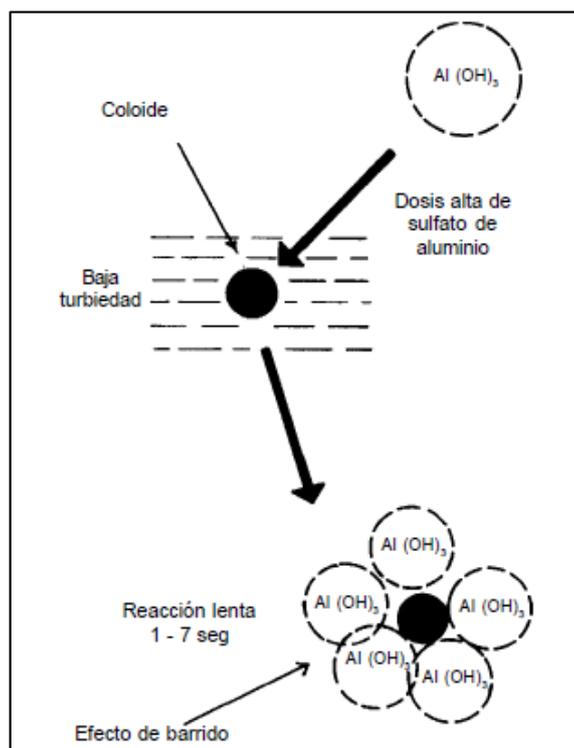


Figura 14: Coagulación por Barrido

FUENTE: CEPIS (2004)

2.4. Aplicación práctica de los coagulantes

2.4.1. Requisitos principales:

La aplicación de los coagulantes desde el punto de vista práctico en la operación de una planta de tratamiento de agua potable, requieren tener en consideración los siguientes aspectos:

2.4.2. Verificación del caudal de tratamiento

Para la verificación se debe de considerar dos aspectos fundamentales:

- a. Calibración del Equipo de Medición (caudalímetro; correntóm; etc.)
- b. Ajuste de las Curvas de Calibración para el Punto de Medición y verificación de las curvas de medición para cada condición de flujo.

2.4.3. Dosificación de productos químicos

a. Estados de presentación productos químicos

Productos químicos sólidos.- Deben ser utilizados después de haber sido puestos en solución y pueden ser aplicados de la siguiente manera:

- **En continuo:** la dosis es calibrada por medio de un dosificador en seco del tipo volumétrico, la disolución se debe realizar dentro de un tanque de nivel constante provisto de un agitador (aplicación de Sulfato de Aluminio Granular).
- **Por lotes o Batch:** el operador prepara puntualmente una solución o una suspensión de cierta cantidad de producto y luego realiza la dosificación
- **Productos líquidos:** son utilizados puros o diluidos por medio de equipos de bombeo o por sistemas de gravedad aplicación de Sulfato de Aluminio.

b. Aplicación de productos químicos

La aplicación de productos químicos en la planta requiere de las siguientes precauciones fundamentales:

- En la concentración de las soluciones, se deben tener en cuenta los límites de solubilidad y la naturaleza del agua de dilución. No realizar diluciones sin control, podrían producirse hidrólisis antes de la aplicación, generado dificultad en la determinación del consumo real de los productos químicos.
- La dispersión, se debe realizar a través de un sistema de dispersión para evitar la formación de los aglomerados que son difíciles de disolverse.
- Debe haber la agitación necesaria, para conseguir la mezcla completa de los productos químicos. En el caso de los polielectrolitos es recomendable agitar 30 minutos más, después de haber sido preparado, siendo este un requisito para el desarrollo completo de la cadena polimérica.

c. Medida de la concentración de una solución o suspensión

La utilización de un densímetro y el análisis de la curva correspondiente entre la densidad y la concentración de la solución estimada, nos permite conocer la concentración real en

el momento de la medición. Por ejemplo, en cada recepción del Sulfato de Aluminio (solución) se mide la densidad de la solución.

d. Medida de caudal inyectado

Uno de los elementos importantes es la medición del caudal que se inyecta para el tratamiento de agua, donde se debe tener en consideración los siguientes aspectos:

- a. Si la aplicación del coagulante es por gravedad, la variación de la altura en el tanque de almacenamiento, así como las pruebas de aforamiento permiten conocer rápidamente el caudal del producto químico aplicado.
- b. Si la aplicación es realizada por medio del sistema de bombeo, se debe verificar las curvas de calibración de las bombas, verificando las condiciones de concentración, viscosidad, presión para los cuales se pueden utilizar y deben ser verificados por las pruebas de aforamiento.

Los siguientes dispositivos de medición, que permitieron realizar un mejor control de la dosificación son:

- a. Un rotámetro, que se utilizó para medir el volumen de agua de dilución.
- b. Un cronómetro y un recipiente graduado, que se utilizaron en las pruebas de aforamiento. La medida se realizó en la descarga inmediata de la bomba o en el punto de aplicación.
- e. Distribución del coagulante en la unidad de mezcla rápida

La distribución de la solución debe ser uniforme en la mezcla del agua, al mismo tiempo debe recibir igual cantidad del coagulante.

2.5. Calidad de agua

SEDAM Huancayo en sus plantas de tratamiento de aguas crudas superficiales, esta regidas por los estándares de Calidad de Agua del Ministerio del Ambiente. Clasificándose como Categoría 1: Poblacional y Recreacional y de clase A2 que pueden ser potabilizadas con tratamiento convencional.

Por su parte la calidad de agua potable en el Perú está regulada por el “Reglamento de la Calidad del Agua para Consumo Humano” según Decreto Supremo N° 031-2010-SA. Aprobada por la Dirección General de Salud Ambiental (DIGESA) del Ministerio de Salud.

2.5.1. Características organolépticas

Las características de acuerdo a (DIGESA, 2011) se presentan en el siguiente Cuadro 1:

Cuadro 1: Límites máximos permisibles de parámetros de calidad organoléptica

Parámetros	Unidad de medida	Límite máximo permisible
1. Olor	--	Aceptable
2. Sabor	--	Aceptable
3. Color	UCV escala Pt/Co	15
4. Turbiedad	UNT	5
5. pH	Valor de pH	6,5 a 8,5
6. Conductividad (25°C)	µmho/cm	1 500
7. Sólidos totales disueltos	mgL ⁻¹	1 000
8. Cloruros	mg Cl ⁻ L ⁻¹	250
9. Sulfatos	mg SO ₄ ⁼ L ⁻¹	250
10. Dureza total	mg CaCO ₃ L ⁻¹	500
11. Amoniaco	mg N L ⁻¹	1,5
12. Hierro	mg Fe L ⁻¹	0,3
13. Manganeso	mg Mn L ⁻¹	0,4
14. Aluminio	mg Al L ⁻¹	0,2
15. Cobre	mg Cu L ⁻¹	2,0
16. Zinc	mg Zn L ⁻¹	3,0
17. Sodio	mg Na L ⁻¹	200

UCV = Unidad de color verdadero

UNT = Unidad nefelométrica de turbiedad

FUENTE: DIGESA (2011)

2.5.2. Características microbiológicas y parasitológicas

Según la clasificación que indica en Ministerio de Salud (DIGESA, 2011), se considera con riesgo para la salud a los microorganismos patógenos que pueden estar presentes en aguas superficiales y cuyo consumo hídrico puede causar enfermedades, los límites máximos permisibles se presentan en el Cuadro 2.

Cuadro 2: Límites máximos permisibles de parámetros microbiológicos y parasitológicos

Parámetros	Unidad de medida	Límite máximo permisible
1. Bacterias Coliformes Totales.	UFC/100 mL a 35°C	0 (*)
2. E. Coli	UFC/100 mL a 44,5°C	0 (*)
3. Bacterias Coliformes Termotolerantes o Fecales.	UFC/100 mL a 44,5°C	0 (*)
4. Bacterias Heterotróficas	UFC/mL a 35°C	500
5. Huevos y larvas de Helmintos, quistes y ooquistes de protozoarios patógenos.	Nº org/L	0
6. Virus	UFC / mL	0
7. Organismos de vida libre, como algas, protozoarios, copépodos, rotíferos, nemátodos en todos sus estadios evolutivos	Nº org/L	0

UFC = Unidad formadora de colonias

(*) En caso de analizar por la técnica del NMP por tubos múltiples = < 1,8 /100 ml

FUENTE: DIGESA (2011)

2.6. Principios de la red neuronal artificial

2.6.1. Redes neuronales

Las redes neuronales artificiales (RNA) son modelos matemáticos que intentan reproducir el aprendizaje y procesamiento automático inspirado en la forma en que funciona el sistema nervioso. Este sistema de interconexión de neuronas que colaboran entre sí para producir un estímulo de salida. En inteligencia artificial es frecuente referirse a ellas como redes de neuronas o redes neuronales. Como todo modelo, realizan una simplificación del sistema real que simulan y se toman las características principales del mismo para la resolución de una tarea determinada.

a. El modelo biológico

El cerebro es el elemento principal del sistema nervioso humano y está compuesto por un tipo especial de célula llamada neurona. Una neurona es una célula viva y como tal posee todos los elementos comunes de las células biológicas. A su vez, las neuronas tienen características propias que le permiten comunicarse entre ellas, lo que las diferencia del resto de las células biológicas. La figura 15 se muestra la estructura típica de una neurona biológica.

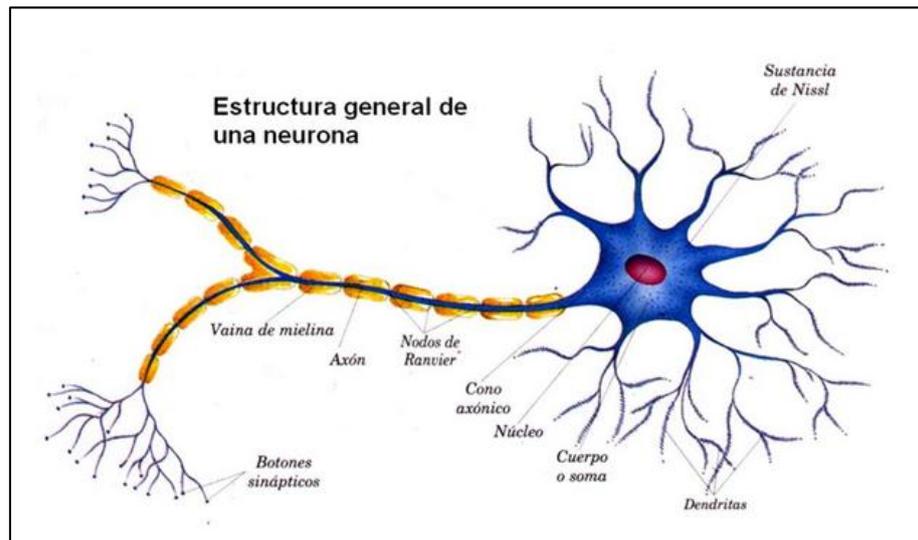


Figura 15: Estructura de una neurona biológica

FUENTE: Inteligencia Artificial (2015)

De la figura 15 se observa que la neurona biológica está compuesta por un *cuerpo celular* o *soma*, del cual se desprende árbol de ramificaciones llamado *árbol dendrítico*, compuesto por las *dendritas*. Del soma también parte una fibra tubular, llamada *axón*, el cual suele ramificarse cerca de su extremo. Las dendritas actúan como un canal de entrada de señales provenientes desde el exterior hacia la neurona, mientras que el axón actúa como un canal de salida. El espacio entre dos neuronas vecinas se denomina *sinapsis*. En el córtex cerebral se observa una organización horizontal en capas, así como también una organización vertical en columnas de neuronas.

La intensidad de una sinapsis no es fija, sino que puede ser modificada en base a la información proveniente del medio. De esta manera la estructura del cerebro no permanece fija sino que se va modificando por la formación de nuevas conexiones, ya sean excitadoras o inhibitoras, la destrucción de conexiones, la modificación de la intensidad de la sinapsis, o incluso por muerte neuronal.

Desde un punto de vista funcional, las neuronas conforman un procesador de información sencillo. Constan de un subsistema de entrada (dendritas), un subsistema de procesamiento (el soma) y un subsistema de salida (axón).

Como se mencionó antes, una de las características principales de las neuronas, y que las distinguen del resto de las células, es su capacidad de comunicarse. Las señales nerviosas pueden ser eléctricas o químicas. La transmisión química se da principalmente en la comunicación entre neuronas, mientras que la eléctrica se produce dentro de una neurona (García Martínez *et al.*, 2003). En general, una neurona recibe información de cientos de neuronas vecinas y la transmite a otras tantas neuronas.

La comunicación entre neuronas se lleva a cabo de la siguiente manera: en el soma de las neuronas transmisoras o presinápticas se genera un pulso eléctrico llamado potencial de acción. El pulso eléctrico se propaga a través del axón en dirección a las sinapsis. La información se transmite a las neuronas vecinas utilizando un proceso químico, mediante la liberación de neurotransmisores. Estos neurotransmisores se transmiten a través de la sinapsis hacia la neurona receptora. La neurona receptora o postsináptica toma la señal enviada por cientos de neuronas a través de las dendritas y la transmite al cuerpo celular. Estas señales pueden ser excitadoras *positivas* o inhibitoras *negativas* (Gurney, 1997). El soma es el encargado de integrar la información proveniente de las distintas neuronas. Si la señal resultante supera un determinado umbral (umbral de disparo) el soma emite un pulso que se transmite a lo largo del axón dando lugar a la transmisión eléctrica a lo largo de la neurona. Al llegar la señal al extremo del axón se liberan neurotransmisores que permiten transmitir la señal a las neuronas vecinas. (Nascimento, 1994).

2.6.2. Estructura de un sistema neuronal artificial

Como se dijo anteriormente, las redes neuronales son modelos matemáticos que intentan el aprendizaje y procesar de forma automática inspirado en el sistema nervioso. El principal objetivo de este modelo es la construcción de sistemas capaces de lograr el aprendizaje para representar cierto comportamiento inteligente. Según, esto implica la capacidad de aprender a realizar una determinada tarea.

Las características principales que reproducen las redes neuronales artificiales se pueden reducir a los siguientes tres conceptos: procesamiento paralelo, distribuido y adaptativo. (Del Brio y Sanz Molina, 2002)

El verdadero poder de este modelo radica en el procesamiento paralelo realizado por las neuronas artificiales. La neurona artificial es un elemento de procesamiento simple y constituye el elemento principal de un sistema neuronal artificial.

Estas neuronas artificiales se combinan en estructuras denominadas capas. Una red neuronal artificial esta un compuesta por un conjunto de capas. De esta manera, la información se encuentre distribuida a lo largo de las sinapsis de la red, dándole a este sistema cierta tolerancia a fallos.

A su vez, las redes neuronales artificiales son capaces de adaptar su funcionamiento a distintos entornos modificando sus conexiones entre neuronas, de esta manera pueden aprender de la experiencia y generalizar conceptos.

Por último, un conjunto de redes neuronales, junto con las interfaces de entrada y salida, y los módulos lógicos adicionales conforman un sistema neuronal artificial.

2.6.3. Modelo de neurona artificial

La neurona artificial es un elemento de procesamiento simple que a partir de un vector de entradas produce una única salida. En general podemos encontrar tres tipos de neuronas artificiales, donde cada una de las cuales tiene su contraparte en el sistema nervioso:

- a. Las que reciben información directamente desde el exterior, a las cuales se las denomina neuronas de entrada.

- b. Las que reciben información desde otras neuronas artificiales, a las cuales se las denomina neuronas ocultas. Es en estas neuronas, en particular en sus sinapsis, donde se realiza la representación de la información almacenada.
- c. Las que reciben la información procesada y las devuelven al exterior.

A estas neuronas se las denomina neuronas de salida.

La figura 16 muestra los elementos que componen un modelo de neurona artificial:

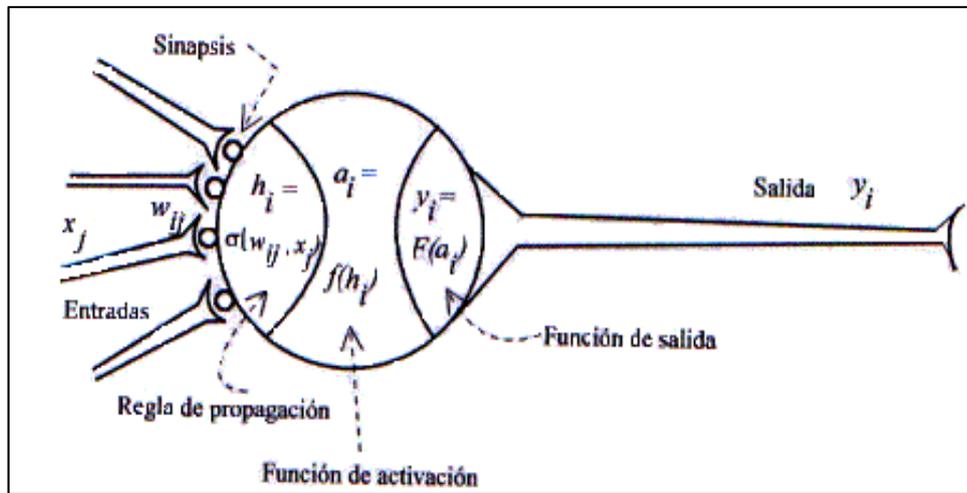


Figura 16: Modelo de neurona artificial

FUENTE: Griffiths y Andrews (2011)

Se puede observar que el modelo tiene entradas, una función de activación, las reglas de propagación, la sinapsis y la función de salida. A continuación se define cada uno de ítems señalados.

- a. **Conjunto de entradas, $x_j(t)$.** Estas pueden ser provenientes del exterior o de otras neuronas artificiales.
- b. **Peso sinápticos, w_{ij} .** Representan el grado de comunicación entre la neurona artificial j y la neurona artificial i . Pueden ser excitadores o inhibidores
- c. **Regla de propagación, $\sigma_i(w_{ij}, x_j(t))$.** Integra la información proveniente de las distintas neuronas artificiales y proporciona el valor del potencial postsináptico de la neurona i .
- d. **Función de activación, $f_i(a_i(t-1), h_i(t))$.** Provee el estado de activación actual de la neurona i .

e. **Función de salida, $F_i(a_i(t))$.** Representa la salida actual de la neurona i .

De esta forma, la salida producida por una neurona i , para un determinado instante de tiempo t puede ser escrita en forma general de la siguiente manera:

$$y_i(t) = F_i(f_i [a_i(t - 1), \sigma_i (w_{ij}, x_j(t))]) \quad (2.1)$$

A continuación se estudian cada uno de los puntos introducidos anteriormente.

2.6.4. Entradas y salidas

Las entradas y salidas de una neurona pueden ser clasificadas en dos grandes grupos, binarias o continuas. Las neuronas binarias (digitales) sólo admiten dos valores posibles. En general en este tipo de neurona se utilizan los siguientes dos alfabetos $\{0,1\}$ o $\{-1,1\}$. Por su parte, las neuronas continuas (analógicas) admiten valores dentro de un determinado rango, que en general suele definirse como $[-1,1]$.

La selección del tipo de neurona a utilizar depende de la aplicación y del modelo a construir.

2.6.5. Pesos sinápticos

El peso sináptico w_{ij} define la fuerza de una conexión sináptica entre dos neuronas, la neurona presináptica i y la neurona postsináptica j . Los pesos sinápticos pueden tomar valores positivos, negativos o cero. En caso de una entrada positiva, un peso positivo actúa como excitador, mientras que un peso negativo actúa como inhibidor. En caso de que el peso sea cero, no existe comunicación entre el par de neuronas.

Mediante el ajuste de los pesos sinápticos la red es capaz de adaptarse a cualquier entorno y realizar una determinada tarea.

2.6.6. Regla de propagación

La regla de propagación determina el potencial resultante de la interacción de la neurona i con las N neuronas vecinas. El potencial resultante h_i se puede expresar de la siguiente manera:

$$h_i(t) = \sigma_i(w_{ij}, x_j(t)) \quad (2.2)$$

La regla de propagación más simple y utilizada consiste en realizar una suma de las entradas ponderadas con sus pesos sinápticos correspondientes:

$$h_i(t) = \sum_j w_{ij} * x_j(t) \quad (2.3)$$

2.6.7. Función de activación

La función de activación determina el estado de activación actual de la neurona en base al potencial resultante h_i y al estado de activación anterior de la neurona $a_i(t-1)$. El estado de activación de la neurona para un determinado instante de tiempo t puede ser expresado de la siguiente manera:

$$a_i(t) = f_i(a_i(t-1), h_i(t)) \quad (2.4)$$

Sin embargo, en la mayoría de los modelos se suele ignorar el estado anterior de la neurona, definiéndose el estado de activación en función del potencial resultante h_i :

$$a_i(t) = f_i(h_i(t)) \quad (2.5)$$

A continuación se muestra un listado de algunas de las funciones de activación más utilizadas en los distintos modelos de redes neuronales artificiales.

a. Función escalón.

La función de activación escalón se asocia a neuronas binarias en las cuales, cuando la suma de las entradas es mayor o igual que el umbral de la neurona, la activación es 1; si es menor la activación es 0 (ó -1). (Ver figura 17)

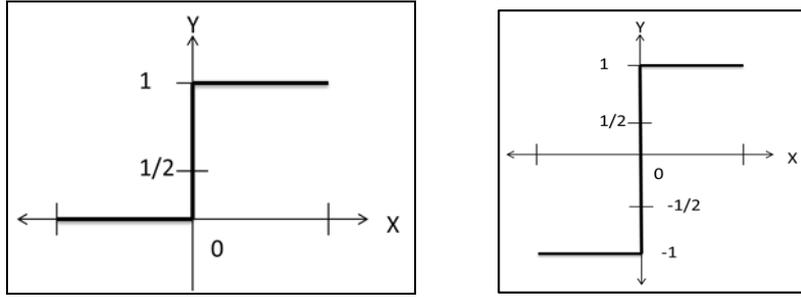


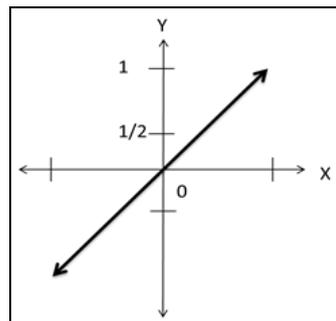
Figura 17: Función escalón

$$F_k(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si } x < 0 \end{cases}$$

$$F_k(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ -1 & \text{si } x < 0 \end{cases}$$

b. Función lineal mixta.

La función lineal mixta o identidad responde a la expresión $F_k(u) = u$. En las neuronas con función mixta, si la suma de las señales de entrada es menor que un límite inferior, la función se define como 0 (o -1). Si dicha suma es mayor o igual que el límite superior, entonces la activación es 1. Si la suma de entrada está comprendida entre ambos límites, superior e inferior, entonces la activación se define como una función lineal de la suma de las señales de entrada. (Figuras 18, 19 y 20)



$$F_k(x) = x:$$

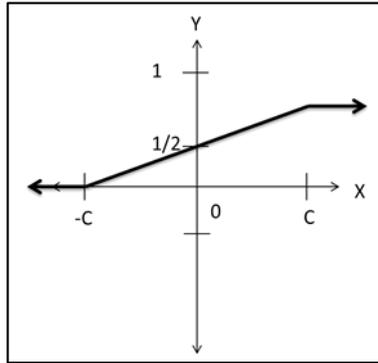


Figura 18: Función mixta caso a

$$F_k(x) = \begin{cases} 0 & \text{si } x < -C \\ 1 & \text{si } x > C \\ \frac{x}{2c} + \frac{1}{2} & \text{en otro caso} \end{cases}$$

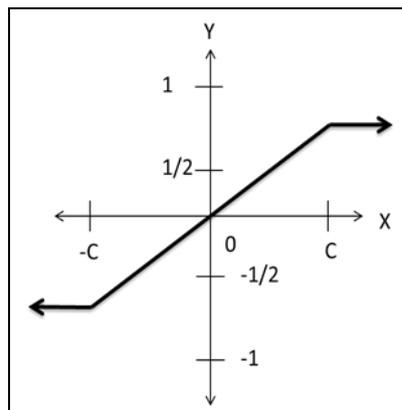


Figura 19: función mixta: caso b

$$F_k(x) = \begin{cases} -1 & \text{si } x < -C \\ 1 & \text{si } x > C \\ ax & \text{en otro caso} \end{cases}$$

c. Función tangente hiperbólica.

La función de activación tangente hiperbólica se emplea en los casos que presentan variaciones suaves de valores positivos y negativos de la señal a clasificar. Como se

puede ver en su descripción es una de las funciones más empleadas en entrenamientos supervisados, como en el caso del entrenamiento de retropropagación del error.

Debe de tenerse cuidado de emplear esta figura entre los umbrales positivos y negativos antes de la saturación, de otra forma la salida siempre generará valores saturados iguales a 1 y -1.

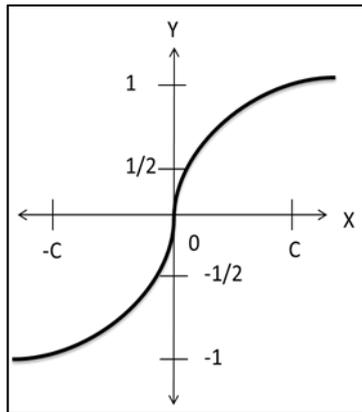


Figura 20: función hiperbólica

$$F_k(u) = \frac{e^u - e^{-u}}{e^u + e^{-u}}$$

d. Función sigmoideal.

Con la función sigmoideal el valor dado por la función es cercano a uno de los valores asintóticos. Esto hace que en la mayoría de los casos, el valor de salida esté comprendido en la zona alta o baja del sigmoide. De hecho, cuando la pendiente es elevada, esta función tiende a la función escalón. Sin embargo, la importancia de la función sigmoideal es que su derivada siempre es positiva y cercana a cero para los valores grandes positivos o negativos; además, toma su valor máximo cuando $x = 0$. Esto hace que se puedan utilizar reglas de aprendizaje definidas para las funciones escalón, con la ventaja, respecto a esta función, de que la derivada está definida en todo intervalo.

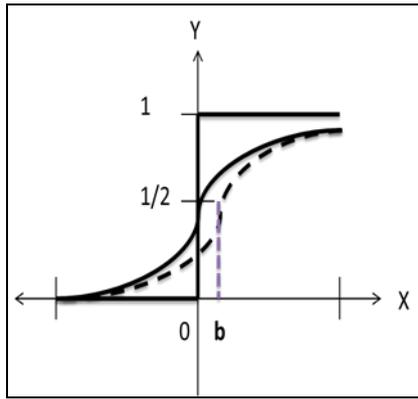


Figura 21: Función sigmoial

$$F_k(u) = \frac{1}{1 + e^{-u}}$$

e. Función de Gauss.

Los mapeos ocultos algunas veces pueden realizarse con un solo nivel de neuronas mediante el uso de funciones de activación tipo Gauss de acuerdo a la figura 22, en lugar de funciones tipo sigmoiales.

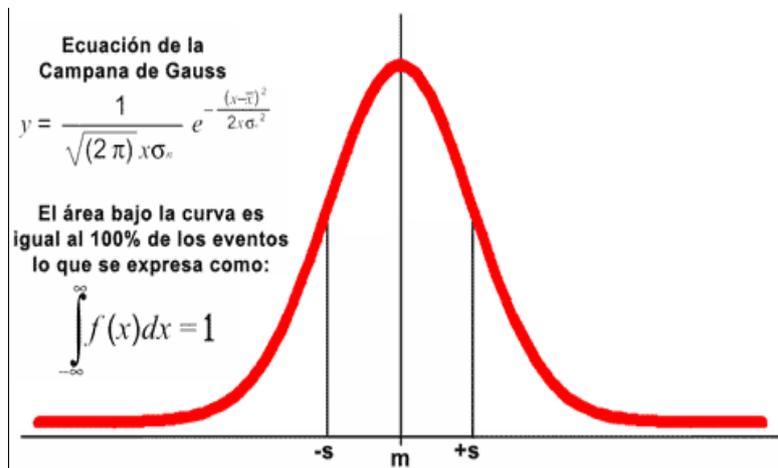


Figura 22: función Gaussiana

$$F_k(X) = \frac{1}{\sigma \sqrt{2\pi}} e^{\left(\frac{x^2}{2\sigma^2}\right)}$$

2.6.8. Función de salida

La función de salida proporciona el valor de salida de la neurona, en base al estado de activación de la neurona. En general se utiliza la función identidad, es decir:

$$y_i(t) = F_i(a_i(t)) = a_i(t) \quad (2.6)$$

2.6.9. Arquitectura de una red neuronal

Una vez definida el tipo de neurona que se utilizará en un modelo de redes neuronales artificiales es necesario definir la topología de la misma.

La organización y disposición de las neuronas dentro de una red neuronal se denomina topología, y viene dada por el número de capas, la cantidad de neuronas por capa, el grado de conectividad, y el tipo de conexión entre neuronas.

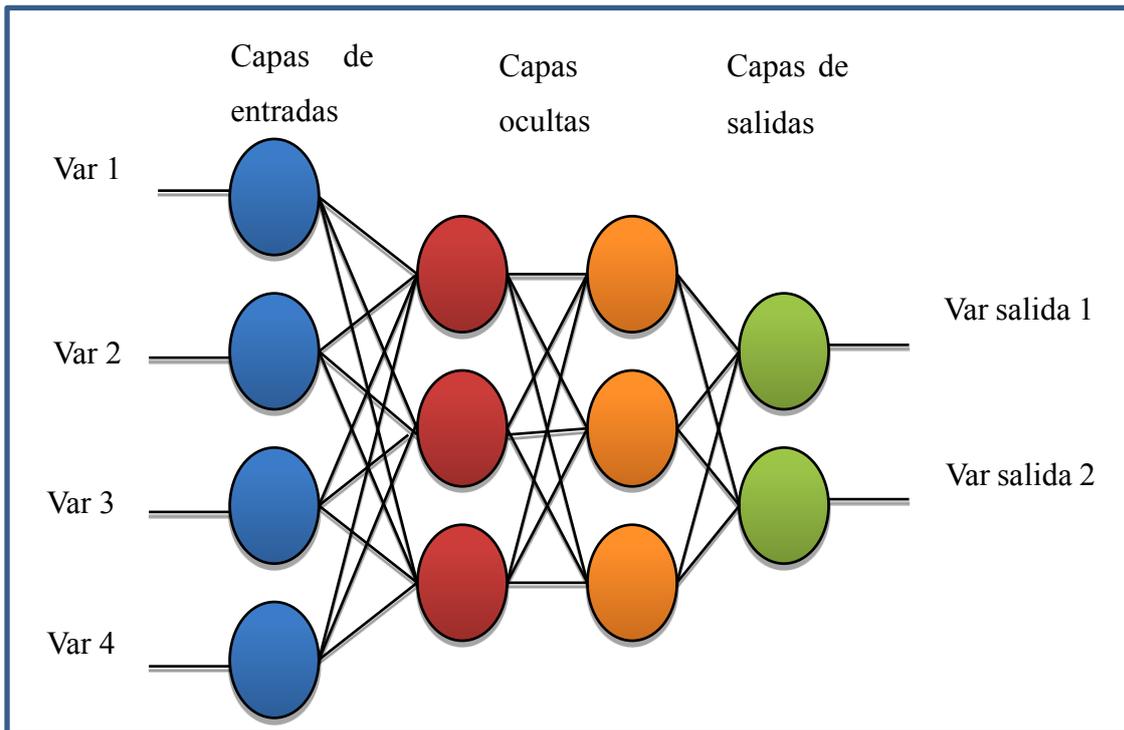


Figura 23: Arquitectura común de una red neuronal artificial

Las neuronas suelen agruparse en unidades funcionales denominadas capas. Se denomina capa de entrada a aquella que está compuesta por neuronas de entradas y por lo tanto recibe información procedente desde el exterior. Análogamente, se denomina capa oculta y capa de salida a aquellas capas que están compuestas por neuronas ocultas y de salida

respectivamente. Una red neuronal artificial está compuesta por una o más capas, las cuales se encuentran interconectadas entre sí.

Entre un par de neuronas de la red neuronal artificial pueden existir conexiones. Estas conexiones son las sinapsis, tienen asociadas un peso sináptico, y son direccionales.

Cuando la conexión se establece entre dos neuronas de una misma capa hablamos de conexiones laterales o conexiones intra-capas. Por el contrario, si la conexión se establece entre neuronas de distintas capas se la denomina conexión inter-capas. Si la conexión se produce en el sentido inverso al de entrada-salida la conexión se llama recurrente o realimentada.

Una red puede estar formada por una única capa de neuronas. En este caso hablamos de redes monocapa, y las neuronas que conforman dicha capa cumplen la función de neuronas de entrada y salida simultáneamente. Cuando la red está compuesta por dos o más capas hablamos de redes multicapa.

A su vez, hablamos de redes neuronales con conexión hacia adelante (redes feedforward) cuando las conexiones entre las distintas neuronas de la red siguen un único sentido, desde la entrada de la red hacia la salida de la misma. Cuando las conexiones pueden ser tanto hacia adelante como hacia atrás hablamos de redes recurrentes (redes feedback).

2.6.10. Aprendizaje

Durante la operación de una red neuronal podemos distinguir claramente dos fases o modos de operación: la fase de aprendizaje o entrenamiento, y la fase de operación o ejecución.

Durante la primera fase, la fase de aprendizaje, la red es entrenada para realizar un determinado tipo de procesamiento. Una vez alcanzado un nivel de entrenamiento adecuado, se pasa a la fase de operación, donde la red es utilizada para llevar a cabo la tarea para la cual fue entrenada.

2.6.11. Fase de entrenamiento.

Una vez seleccionada el tipo de neurona artificial que se utilizará en una red neuronal y determinada su topología es necesario entrenarla para que la red pueda ser utilizada. Partiendo de un conjunto de pesos sinápticos aleatorio, el proceso de aprendizaje busca un conjunto de pesos que permitan a la red desarrollar correctamente una determinada tarea. Durante el proceso de aprendizaje se va refinando iterativamente la solución hasta alcanzar un nivel de operación suficientemente bueno.

El proceso de aprendizaje se puede dividir en tres grandes grupos de acuerdo a sus características (Isasi y Galván, 2004)

- ***Aprendizaje supervisado.***- Se presenta a la red un conjunto de patrones de entrada junto con la salida esperada. Los pesos se van modificando de manera proporcional al error que se produce entre la salida real de la red y la salida esperada.
- ***Aprendizaje no supervisado.***- Se presenta a la red un conjunto de patrones de entrada. No hay información disponible sobre la salida esperada. El proceso de entrenamiento en este caso deberá ajustar sus pesos en base a la correlación existente entre los datos de entrada.
- ***Aprendizaje por refuerzo.***- Este tipo de aprendizaje se ubica entre medio de los dos anteriores. Se le presenta a la red un conjunto de patrones de entrada y se le indica a la red si la salida obtenida es o no correcta. Sin embargo, no se le proporciona el valor de la salida esperada. Este tipo de aprendizaje es muy útil en aquellos casos en que se desconoce cuál es la salida exacta que debe proporcionar la red.

2.6.12. Fase de operación

Una vez finalizada la fase de aprendizaje, la red puede ser utilizada para realizar la tarea para la que fue entrenada. Una de las principales ventajas que posee este modelo es que la red aprende la relación existente entre los datos, adquiriendo la capacidad de generalizar conceptos. De esta manera, una red neuronal puede tratar con información que no le fue presentada durante de la fase de entrenamiento.

2.7. Redes neuronales con conexión hacia delante

Las redes neuronales artificiales con conexión hacia delante son el tema central de esta tesis. Este tipo de red, que se caracteriza por su organización en capas y conexiones estrictamente hacia delante, utiliza algoritmos de entrenamiento del tipo supervisado.

Este grupo de red es el más utilizado en aplicaciones prácticas que utilicen redes neuronales, obteniéndose muy buenos resultados fundamentalmente como clasificadores de patrones y estimadores de funciones.

Dentro de este grupo de redes neuronales encontramos al perceptrón, la red Adaline/Madaline, y al perceptrón multicapa.

2.7.1. Perceptrón

Este modelo tiene gran importancia histórica ya que fue el primer modelo en poseer un mecanismo de entrenamiento que permite determinar automáticamente los pesos sinápticos que clasifican correctamente a un conjunto de patrones a partir de un conjunto de ejemplos.

La arquitectura del perceptrón está compuesta por dos capas de neuronas, una de entrada y una de salida. La capa de entrada es la que recibe la información proveniente del exterior y la transmite a las neuronas sin realizar ningún tipo de operación sobre la señal de entrada. En general la información entrante es binaria. La función de activación de las neuronas de un perceptrón es del tipo escalón, dando de esta manera sólo salidas binarias. Cada neurona de salida del perceptrón representa a una clase. Mientras que la neurona de salida responde con 1 si el vector de entrada pertenece a la clase a la que representa y responde con 0 en caso contrario.

La operación de un perceptrón con n neuronas de entrada y m neuronas de salidas puede ser resumida de la siguiente manera:

$$y_i(t) = f(\sum_{j=1}^n w_{ij}x_j - \theta_i) \quad \forall i, \quad 1 \leq i \leq m \quad (2.7)$$

El algoritmo de entrenamiento del perceptrón se encuentra dentro de los denominados algoritmos por corrección de errores. Este tipo de algoritmos ajustan los pesos de manera proporcional a la diferencia entre la salida actual proporcionada por la red y la salida objetivo, con el fin de minimizar el error producido por la red.

Se puede demostrar que este método de entrenamiento converge siempre en un tiempo finito y con independencia de los pesos de partida, siempre que la función a representar sea linealmente separable. El principal problema de este método de entrenamiento es que cuando

la función a representar no es linealmente separable el proceso de entrenamiento oscilará y nunca alcanzará la solución. Las funciones no separables linealmente no pueden ser representadas por un perceptrón.

2.7.2. Adaline / Madaline

Otro de los modelos que tienen gran importancia es la red neuronal Adaline. La topología de la red Adaline es similar a la del perceptrón sólo que en este caso la función de salida de las neuronas es lineal. Dado que las señales de entrada pueden ser continuas, la red Adaline es un dispositivo de entrada/salida analógica (continua) a diferencia del perceptrón que de acuerdo a lo dicho anteriormente es un dispositivo entrada/salida digital (binaria).

La operación de una red Adaline con n neuronas de entrada y m neuronas de salidas puede ser resumida de la siguiente manera:

$$y_i(t) = \sum_{j=1}^n w_{ij}x_j - \theta_i \quad \forall i, 1 \leq i \leq m \quad (2.8)$$

Sin embargo, la principal diferencia entre la red Adaline y el perceptrón consiste en la regla de aprendizaje que utilizan. En el caso de la red Adaline implementa como método de aprendizaje la regla de Widrow-Hoff, también conocida como regla LMS (Least Mean Squares, mínimos cuadrados), que realiza una actualización continua de los pesos sinápticos de acuerdo a la contribución de cada neurona sobre el error total de la red.

Este método produce un conjunto de pesos sinápticos óptimos desde el punto de vista de los mínimos cuadrados (un conjunto de pesos que minimiza el error cuadrático que comete la red), y en caso de que los vectores de entrada sean linealmente independientes produce una asociación perfecta entre entradas-salidas.

Existe una versión multicapa de la Adaline denominada Madaline (Múltiple Adaline, múltiples Adalides) que consiste en una red neuronal con neuronas similares a las de la Adaline pero que contiene capas de neuronas ocultas.

2.7.3. Perceptrón multicapa

El perceptrón multicapa es una extensión del perceptrón simple. La topología de un perceptrón multicapa está definida por un conjunto de capas ocultas, una capa de entrada y

una de salida. No existen restricciones sobre la función de activación aunque en general se suelen utilizar funciones sigmoideas.

La operación de un perceptrón multicapa con una única capa oculta puede ser resumida de la siguiente manera:

$$z_k = \sum_j w'_{kj} y_j - \theta'_k = \sum_j w'_{kj} f\left(\sum_i w_{ji} x_i - \theta_j\right) - \theta'_k \quad (2.9)$$

Este modelo es el más utilizado en la actualidad. El espectro de aplicaciones del perceptrón multicapa es muy amplio lo que hace muy difícil enumerar sus aplicaciones más relevantes. Sin embargo, podemos mencionar algunas áreas de aplicación:

- Codificación de información
- Traducción de texto en lenguaje hablado
- Reconocimiento óptico de caracteres (OCR)

La popularidad de este modelo de redes neuronales no se debe únicamente al éxito obtenido en aplicaciones prácticas del mismo. Existen demostraciones teóricas que permiten explicar el éxito de dichas aplicaciones. En Funahashi, KI, (1989) se demuestra que un perceptrón multicapa cuya función de activación sea no constante, acotada y monótona creciente es un aproximador universal de funciones. En Hornik *et al.*, (1989) se llega a un resultado similar utilizando funciones de activación sigmoideas, no necesariamente continuas.

2.8. Entrenamiento de redes neuronales

En el contexto de las redes neuronales el aprendizaje puede ser visto como el proceso de ajuste de los parámetros libres de la red (Yao, 1995). Partiendo de un conjunto de pesos sinápticos aleatorio, el proceso de aprendizaje busca un conjunto de pesos que permitan a la red desarrollar correctamente una determinada tarea. El proceso de aprendizaje es un proceso iterativo, en el cual se va refinando la solución hasta alcanzar un nivel de operación suficientemente bueno.

La mayoría de los métodos de entrenamiento utilizados en las redes neuronales con conexión hacia delante consisten en proponer una función de error que mida el rendimiento actual de la red en función de los pesos sinápticos. El objetivo del método de entrenamiento es

encontrar el conjunto de pesos sinápticos que minimizan (o maximizan) la función. El método de optimización proporciona una regla de actualización de los pesos que en función de los patrones de entrada modifica iterativamente los pesos hasta alcanzar el punto óptimo de la red neuronal.

2.8.1. Métodos de gradiente descendente

El método de entrenamiento más utilizado es el método del gradiente descendente. Este método define una función $E(W)$ que proporciona el error que comete la red en función del conjunto de pesos sinápticos W . El objetivo del aprendizaje será encontrar la configuración de pesos que corresponda al mínimo global de la función de error, aunque en muchos casos es suficiente encontrar un mínimo local lo suficientemente bueno (Cauwenberghs, 1993).

El principio general del método es el siguiente: dado un conjunto de pesos $W(0)$ para el instante de tiempo $t=0$, se calcula la dirección de máxima variación del error. La dirección de máximo crecimiento de la función $E(W)$ en $W(0)$ viene dado por el gradiente $\nabla E(W)$. Luego, se actualizan los pesos siguiendo el sentido contrario al indicado por el gradiente $\nabla E(W)$, dirección que indica el sentido de máximo decrecimiento (De Falco *et al.*, 1997). De este modo se va produciendo un descenso por la superficie de error hasta alcanzar un mínimo local.

$$W(t + 1) = W(t) - \alpha \nabla E(W) \quad (2.10)$$

donde α indica el tamaño del paso tomado en cada iteración, pudiendo ser diferente para cada peso e idealmente debería ser infinitesimal. El tamaño del paso es un factor importante a la hora de diseñar un método de estas características. Si se toma un paso muy chico el proceso de entrenamiento resulta muy lento, mientras que si el tamaño del paso es muy grande se producen oscilaciones en torno al punto mínimo.

2.8.2. El algoritmo Backpropagation

El algoritmo *Backpropagation* es el método de entrenamiento más utilizado en redes con conexión hacia delante. Es un método de aprendizaje supervisado de gradiente descendente, en el que se distinguen claramente dos fases: primero se aplica un patrón de entrada, el cual se propaga por las distintas capas que componen la red hasta producir la salida de la misma. Esta salida se compara con la salida deseada y se calcula el error cometido por cada neurona

de salida. Estos errores se transmiten hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de las capas intermedias (Fritsch, 1996). Cada neurona recibe un error que es proporcional a su contribución sobre el error total de la red. Basándose en el error recibido, se ajustan los errores de los pesos sinápticos de cada neurona.

2.8.3. Deducción del algoritmo *Backpropagation*

El algoritmo propone una actualización iterativa de los pesos de la siguiente manera:

$$W(t + 1) = W(t) - \Delta W(t) \quad (2.11)$$

Si tomamos una variación proporcional al gradiente de una función de error $E(W)$ tenemos que:

$$W(t + 1) = W(t) - \alpha \nabla E[W(t)] \quad (2.12)$$

Como se explicó anteriormente el primer paso de este algoritmo consiste en propagar hacia delante un patrón de entrada X_p y obtener la salida de la red Y_p .

La salida de la neurona i viene dada según su estado de activación. Si consideramos la función de salida identidad tenemos que:

$$y_i(t) = F_i(a_i(t)) = a_i(t) \quad (2.13)$$

Siendo

$$a_i(t) = f_i(h_i(t)) \quad (2.14)$$

La regla de propagación más simple y utilizada consiste en realizar una suma de las entradas ponderadas con sus pesos sinápticos correspondientes.

$$h_i(t) = \sum_j w_{ij} * x_j(t) \quad (2.15)$$

Se compara la salida obtenida Y_p con la salida deseada D_p , obteniéndose un error que viene dado por:

$$e_p = \frac{1}{2} \sum_{k=1}^M (d_{pk} - y_{pk})^2 \quad (2.16)$$

Donde k es el índice de neurona para las neuronas de la última capa, y M el total de neuronas de la misma.

El error total de la red está dado por:

$$e = \frac{\sum_{p=1}^P (e_p)}{P} \quad (2.17)$$

Siendo p el índice de ejemplo, y P el número total de ejemplos.

De acuerdo a la ecuación (2.12) la variación de los pesos sinápticos será proporcional al gradiente de la función de error:

$$\Delta w_{ji} = -\alpha \frac{\partial e_p}{\partial w_{ji}} \quad (2.18)$$

Si aplicamos la regla de la cadena a (2.18) obtenemos que:

$$\frac{\partial e_p}{\partial w_{ji}} = \frac{\partial e_p}{\partial h_j} \times \frac{\partial h_j}{\partial w_{ji}} \quad (2.19)$$

La ecuación (2.19) expresa la derivada del error en función de dos derivadas. La derivada del error respecto al potencial resultante h_j indica como varia el error al variar la entrada de la neurona j, mientras que la derivada con respecto al peso sináptico w_{ji} indica como varia la entrada de la neurona j al variar el peso de la conexión que va desde la neurona i hasta la neurona j.

El segundo término de la expresión (2.19) lo podemos expresar a partir de la ecuación (2.15) de la siguiente manera

$$\frac{\partial h_j}{\partial w_{ji}} = \frac{\partial \sum_i w_{ji} y_{pi}}{\partial w_{ji}} = y_{pi} \quad (2.20)$$

Si escribimos al primer término de la ecuación (2.19) como

$$\frac{\partial e_p}{\partial h_j} = -\delta_{pj} \quad (2.21)$$

Tenemos que:

$$\frac{\partial e_p}{\partial w_{ji}} = -\delta_{pj} y_{pj} \quad (2.22)$$

Y por lo tanto la ecuación (2.18) queda expresada de la siguiente manera:

$$\Delta w_{ji} = -\delta_{pj} y_{pj} \quad (2.23)$$

Para calcular el valor de delta se vuelve a aplicar la regla de la cadena:

$$\delta_{pj} = \frac{\partial e_p}{\partial h_j} = -\left(\frac{\partial e_p}{\partial y_{pj}} \frac{\partial y_{pj}}{\partial h_j}\right) \quad (2.24)$$

El cálculo del segundo término de la ecuación (2.24) es simple si observamos las ecuaciones (2.13) y (2.14).

$$\frac{\partial y_{pj}}{\partial h_j} = \frac{\partial f_j(h_j)}{\partial h_j} = f'_j(h_j) \quad (2.25)$$

Sin embargo, para el cálculo del primer término de la ecuación (2.24) es necesario distinguir entre dos casos diferentes:

a. La neurona j es una neurona de salida

En este caso podemos obtener el segundo término a partir de la ecuación (2.16) ya que el subíndice j es igual al subíndice k.

$$\frac{\partial e_p}{\partial y_{pj}} = \frac{\partial \frac{1}{2} \sum_{j=1}^M (d_{pj} - y_{pj})^2}{\partial y_{pj}} = -(d_{pj} - y_{pj}) \quad (2.26)$$

Así, la variación de los pesos de una conexión que va hacia la capa externa de la red se calcula como:

$$\Delta w_{ji} = \alpha(d_{pj} - y_{pj})f'_j(h_j)y_{pi} \quad (2.27)$$

b. La neurona j es una neurona oculta

En este caso es necesario aplicar nuevamente la regla de la cadena.

$$\frac{\partial e_p}{\partial y_{pj}} = \sum_k \left(\frac{\partial e_p}{\partial h_k} \frac{\partial h_k}{\partial y_{pj}} \right) \quad (2.28)$$

Donde k es el subíndice de las neuronas que pertenecen a la próxima capa. La ecuación (2.28) la podemos reescribir utilizando la ecuación (2.15)

$$\frac{\partial e_p}{\partial y_{pj}} = \sum_k \left(\frac{\partial e_p}{\partial h_k} \frac{\partial (\sum_j w_{kj} y_{pj})}{\partial y_{pj}} \right) = \sum_k \left(\frac{\partial e_p}{\partial h_k} w_{kj} \right) \quad (2.29)$$

Y por la ecuación (2.25) tenemos que:

$$\frac{\partial e_p}{\partial y_{pj}} = \sum_k -\delta_{pk} w_{kj} = \sum_k -\delta_{pj} w_{kj} \quad (2.30)$$

Así, la variación de los pesos de una conexión que va desde una capa hacia otra capa de la red que no sea la externa se calcula como:

$$\Delta w_{ji} = \alpha \sum_k (\delta_{jk} w_{kj}) f'_j(h_j) y_{pi} \quad (2.31)$$

En la implementación del algoritmo, se toma una amplitud de paso que viene dado por la tasa de aprendizaje (α). A mayor tasa de aprendizaje el proceso será más rápido. Sin embargo, si la tasa de aprendizaje es muy alta puede dar lugar a oscilaciones en torno a un mínimo local. Es posible disminuir el impacto de dichas oscilaciones mediante la adición de un momento (β), quedando la expresión (2.23) expresada de la siguiente manera:

$$\Delta w_{ji}(t + 1) = \alpha \delta_{pj} y_{pj} + \beta \Delta w_{ji}(t) \quad (2.32)$$

De esta manera el momento β determina el efecto en el instante $t+1$ del cambio de los pesos realizado en el instante t .

Con este momento se consigue la convergencia de la red en menor número de iteraciones, ya que si la modificación de los pesos en los instantes t y $t+1$ es en la misma dirección, entonces el descenso por la superficie de error en $t+1$ es mayor. En cambio, si la modificación en los pesos en los instantes t y $t+1$ se produce en direcciones opuestas, el paso que se da en $t+1$ es más pequeño, lo que es adecuado, ya que esto significa que se ha pasado por un mínimo.

Resumiendo, el algoritmo *Backpropagation* queda expresado de la siguiente manera:

$$w_{ji}(t + 1) = w_{ji}(t) + [\alpha \delta_{pj} y_{pj} + \beta \Delta w_{ji}(t)]$$

$$\text{siendo } \delta_{pj} = \begin{cases} (d_{pj} - y_{pj}) f'_j(h_j) & \text{si } j \text{ es una neurona de salida} \\ \left(\sum_k \delta_{pk} w_{kj} \right) f'_j(h_j) & \text{si } j \text{ es una neurona oculta} \end{cases}$$

2.8.4. Modos de entrenamiento

Durante la aplicación del algoritmo *Backpropagation*, el aprendizaje se produce mediante la presentación sucesiva de un set de entrenamiento. Cada presentación completa al perceptrón multicapa del set de entrenamiento se denomina *epoch*. Así, el proceso de aprendizaje se repite *epoch* tras *epoch* hasta que los pesos sinápticos se estabilizan y la performance de la red converge a un valor aceptable.

La forma en que se actualizan los pesos sinápticos da lugar a dos modos de entrenamientos distintos, cada uno con sus ventajas y desventajas.

a. Modo Secuencial

En este modo de entrenamiento la actualización de los pesos sinápticos se produce tras la presentación de cada ejemplo de entrenamiento (Yao, 1993), de allí que también es

conocido como modo por patrón. Si un set de entrenamientos posee N ejemplos, el modo secuencial de entrenamiento tiene como resultado N correcciones de pesos sinápticos durante cada epoch.

b. Modo Batch

En este modo de entrenamiento la actualización de los pesos sinápticos se produce una única vez, tras la presentación de todo el set de entrenamiento. Para cada epoch se calcula el error cuadrático medio (2.17) producido por la red. La variación de los peso sinápticos, para un set de entrenamiento de N ejemplos, se puede calcular a partir de las ecuaciones (2.16), (2.17) y (2.18) como:

$$\Delta w_{ji} = -\alpha \frac{\partial e}{\partial w_{ji}} = -\frac{\alpha}{N} \sum_{n=1}^N e_j \frac{\partial e_j}{\partial w_{ji}} \quad (2.33)$$

Luego, la derivada podemos definirla de la misma manera que la definimos previamente.

Si los patrones de entrenamiento se presentan a la red de manera aleatoria, el modo de entrenamiento secuencial convierte a la búsqueda en el espacio de pesos en estocástica por naturaleza, y disminuye la probabilidad de que el algoritmo *Backpropagation* quede atrapado en un mínimo local. Sin embargo, la naturaleza estocástica del modo de entrenamiento secuencial dificulta el establecimiento de condiciones teóricas para la convergencia del algoritmo.

Por su parte, el uso del modo de entrenamiento batch provee una estimación precisa del vector gradiente, garantizando de esta manera la convergencia hacia un mínimo local.

2.8.5. Aceleración del aprendizaje

Como se mencionó previamente las redes el algoritmo *Backpropagation* ha sido utilizado con éxito en gran cantidad de aplicaciones. Sin embargo, el éxito y la velocidad de convergencia de este mecanismo de entrenamiento tienen un alto grado de dependencia de la configuración del mismo. Por ello se han realizado una serie de métodos que permiten mejorar significativamente la performance del algoritmo.

- a. **Modo de actualización.** La actualización secuencial es más rápida computacionalmente y demanda menos recursos que la actualización batch. Esto se produce especialmente cuando el set de datos es muy grande y altamente redundante (Chinrungrueng, 1993).
- b. **Set de datos.** La calidad del set de datos es un factor muy importante a tener en cuenta. Cada ejemplo presentado a la red debe cumplir con las siguientes dos premisas:
 - Maximizar el error de entrenamiento
 - Maximizar la información
- c. **Presentación de los ejemplos.** El modo en que se presentan los ejemplos es otro factor importante a tener en cuenta. La aleatorización del orden en que se presentan los ejemplos en los distintos *epochs* evita que los resultados se vean distorsionados por el orden de los ejemplos
- d. **Función de activación.** El uso de una función de activación adecuada puede acelerar notoriamente el tiempo de entrenamiento. El uso de funciones antisimétricas en general produce mejores tiempos que el uso de funciones no simétricas.
- e. **Valores objetivos.** La selección de los valores objetivos debe hacerse de acuerdo a la función de activación seleccionada. Una técnica que permite acelerar el tiempo de aprendizaje es desplazar el valor objetivo del valor máximo de la función. El algoritmo *Backpropagation* tiende a saturar las neuronas ocultas cuando el valor objetivo es igual al máximo de la función de activación. Cuando esto sucede se produce el efecto de parálisis, lo que produce un aumento en el tiempo total de entrenamiento. Desplazando el valor objetivo un offset e del valor máximo de la función se reduce el riesgo de que las neuronas ocultas se saturen.
- f. **Normalización de las entradas.** Si bien el algoritmo *Backpropagation* no exige que los valores de entrada a la red se encuentren normalizados, esta es una buena técnica para acelerar los tiempos de entrenamiento.
- g. La normalización de las entradas debe realizarse de manera tal que el valor medio de la misma se encuentre cercano a cero.
- h. **Preprocesamiento de los ejemplos.** Se aplica en aquellos casos en que un atributo toma un conjunto discreto de valores. Si un atributo sólo puede tomar N valores diferentes, la entrada de la red puede subdividirse en N entradas, cada una de las cuales representa a una clase. Cada una de estas entradas ahora puede tomar dos valores, verdadero o falso. Esta técnica puede ayudar a mejorar los tiempos de entrenamiento de la red neuronal

2.9. Generalización

Una vez finalizada la fase de aprendizaje, la red puede ser utilizada para realizar la tarea para la que fue entrenada. Una de las principales ventajas que posee este modelo es que la red aprende la relación existente entre los datos, adquiriendo la capacidad de generalizar conceptos. De esta manera, una red neuronal puede tratar con información que no le fue presentada durante de la fase de entrenamiento (Chinrungrueng, 1988).

Cuando se evalúa una red neuronal no sólo es importante evaluar si la red ha sido capaz de aprender los patrones de entrenamiento. Es imprescindible también evaluar el comportamiento de la red ante patrones nunca antes vistos. Esta característica de las redes neuronales se la conoce como capacidad de generalización y es adquirida durante la fase de entrenamiento (Sanger, 1989). Es necesario que durante el proceso de aprendizaje la red extraiga las características de las muestras, para poder luego responder correctamente a nuevos patrones.

De lo dicho anteriormente surge la necesidad de evaluar durante la fase de entrenamiento dos tipos de errores. El error de aprendizaje, que indica la calidad de la respuesta de la red a los patrones de entrenamiento, y el error de generalización, que indica la calidad de la respuesta de la red a patrones nunca antes vistos. Para poder obtener una medida de ambos errores es necesario dividir el set de datos disponibles en dos, el set de datos de entrenamiento, y el set de datos de evaluación. El primero se utiliza durante la fase de entrenamiento para que la red pueda extraer las características de los mismos y, mediante el ajuste de sus pesos sinápticos, la red logre una representación interna de la función. El set de evaluación se utiliza para evaluar la capacidad de generalización de la red.

La causa más común de la pérdida de capacidad de generalización es el sobre aprendizaje. Esto sucede cuando la cantidad de ciclos de entrenamientos tiende a ser muy alta. Se observa que la respuesta de la red a los patrones de entrenamiento es muy buena mientras que la respuesta a nuevos patrones tiende a ser muy pobre. Al aumentar el número de ciclos la red tiende a sobre ajustar la respuesta a los patrones de entrenamiento, a expensas de una menor capacidad de generalización. La figura 24 muestra una situación idealizada de lo dicho anteriormente. En la misma se observa que en un determinado punto la red comienza a perder

capacidad de generalización como consecuencia del sobre aprendizaje de los patrones de entrenamiento.

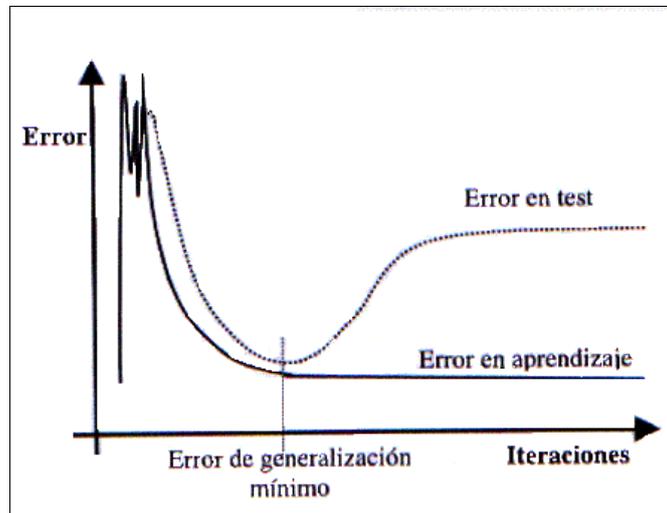


Figura 24. Generalización de situación idealizada

FUENTE: Sanger (1989)

En la figura 25 se muestra una situación más real del mismo caso. A medida que transcurre el proceso de aprendizaje se obtienen varios mínimos sobre el conjunto de evaluación. Existen diversas técnicas de parada temprana (*early stopping*) aunque en la mayoría de los casos se deja que el proceso de aprendizaje avance hasta alcanzar una cota de error razonable, guardando periódicamente las distintas configuraciones intermedias para luego seleccionar la de menor error de evaluación.

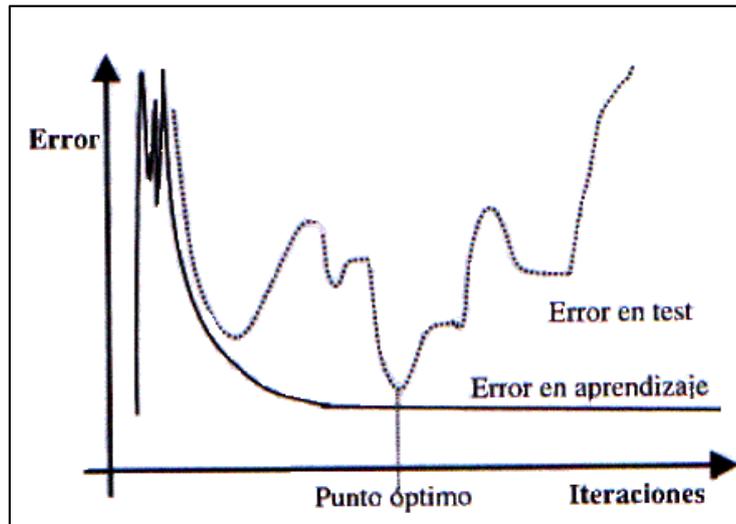


Figura 25. Generalización. Situación real

FUENTE: Sanger (1989)

En ocasiones la pérdida de capacidad de generalización se produce por el uso excesivo de neuronas ocultas en la red neuronal. Esto hace que la red tienda a ajustar con mucha exactitud los patrones de entrenamiento, evitando que la red extraiga las características del conjunto. Este problema se ve agravado cuando los patrones de entrenamiento poseen ruido, ya que la red ajusta también el ruido de los mismos.

2.10. Tipos especiales de redes neuronales

Hay varios tipos de redes neuronales que difieren en estructura, tipo de cálculos que realizan dentro de las neuronas y algoritmos de entrenamiento. Uno de los tipos que se ofrece en el software NeuralTools® de Palisade® es la Red multinivel siempre hacia adelante (MLF). Con las redes MLF, un usuario de NeuralTools puede especificar si debe haber una o dos capas de neuronas ocultas, y cuántas neuronas deben contener las capas ocultas (NeuralTools ofrece ayuda para hacer las selecciones apropiadas, como se describe en la sección redes MLF). NeuralTools también ofrece redes neuronales de regresión generalizada (GRN) y redes neuronales probabilísticas (PN) ambas están estrechamente relacionadas, siendo las primeras para predicciones numéricas, y las últimas para predicciones de clasificación de tipo categórico (cualitativo).

En las redes GRN o PN no hay necesidad de que el usuario tome decisiones sobre la estructura de la red. Estas redes tienen siempre dos capas ocultas de neurona, con una neurona por caso entrenado en la primera capa oculta, y un tamaño de la segunda capa determinado por ciertas características de los datos de entrenamiento.

2.10.1. Redes multinivel siempre hacia adelante

Las Redes multinivel siempre hacia adelante (también conocidas como “Redes de Perceptrón de Múltiples Capas”) son sistemas capaces de aproximación de funciones complejas y, por lo tanto, capaces de modelar relaciones complejas entre variables independientes y una variable dependiente.

2.10.2. La arquitectura MLF

El siguiente diagrama muestra una red MLF para la predicción numérica con tres variables numéricas independientes; la red se ha configurado para que tenga dos neuronas por nodos en la primera capa oculta, y tres neuronas por nodos en la segunda capa oculta. En la figura 26 se muestra la arquitectura de la red multinivel hacia adelante (MLF).

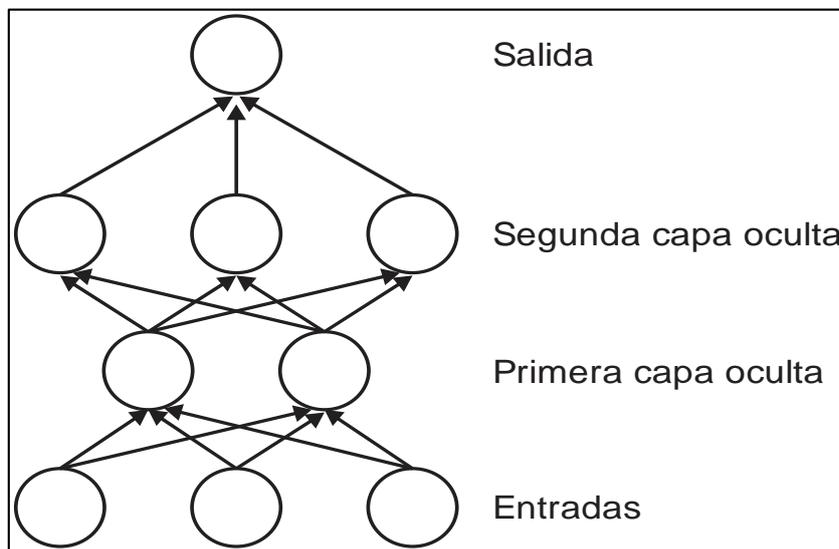


Figura 26: Arquitectura red multinivel hacia adelante (MLF).

FUENTE: Griffiths y Andrews (2011)

2.10.3. La arquitectura GRN

Una red neuronal de regresión generalizada para dos variables numéricas independientes se estructura como se muestra en el gráfico (suponiendo que sólo hay tres casos): (Ver figura 27).

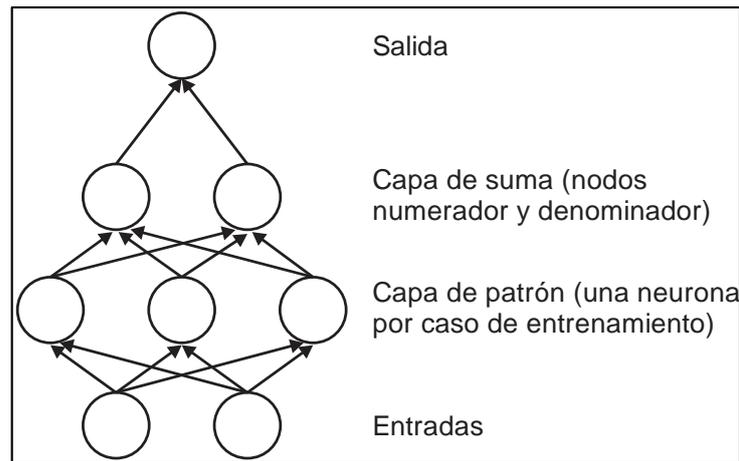


Figura 27: Arquitectura Red de regresión generalizada (GRN)

FUENTE: Heddam *et al.* (2011)

La capa de patrón contiene un nodo por cada caso de entrenamiento. La presentación de un caso de entrenamiento en la red, en este caso consiste en la presentación de dos valores numéricos independientes. Cada neurona de la capa de patrón calcula su distancia con el caso presentado. Los valores transferidos a los nodos numerador y denominador son funciones de la distancia y del valor dependiente. Los dos nodos de la capa de suma suman sus valores de entrada, mientras que el nodo de salida los divide para generar la predicción.

2.10.4. Diseño de la red neuronal artificial.

Una red neuronal es un sistema que imita el cerebro humano en la transformación de entradas en una o más salidas con un conjunto de neuronas. Para encontrar el modelo más eficiente en este estudio se utilizaron las redes multinivel siempre hacia adelante (MLFN) y las redes neuronales probabilísticas (PNN). De modo específico, una función tangente hiperbólica se usa como función de activación en las neuronas de la capa oculta para la red MLFN. La neurona de salida emplea la identidad como función de activación, la cual simplemente

devuelve la suma ponderada de sus entradas. Las redes PNN fueron propuestas primero por (Specht, 1990) y aproximan cualquier función arbitraria entre los vectores de entrada y salida con el trazo de la función estimada de manera directa desde los datos de entrenamiento (Specht, 1991).

El entrenamiento de la red busca identificar el valor del conjunto de pesos o sinapsis que minimizando el error de predicción, logra reproducir las salidas incluidas en el conjunto de datos de entrenamiento.

NeuralTools® respalda diferentes configuraciones de red neuronal para obtener las mejores predicciones posibles. Para la predicción de clasificaciones categorías (en las que la variable dependiente es de tipo categórica), se ofrecen dos tipos de redes: Redes neuronales probabilísticas (PN) y Redes multinivel siempre hacia adelante (MLF). La predicción numérica se puede realizar usando redes MLF, así como Redes neuronales de regresión generalizada (GRN), que están estrechamente relacionadas con las redes PN.

El programa usa un algoritmo de aprendizaje supervisado, el cual necesita un conjunto de datos, donde en cada grupo de entrada existirá una salida esperada, para así poder aproximar una función que los relacione; a este conjunto de datos se les da el nombre de datos de entrenamiento. En este caso en particular, los datos de entrenamiento provendrán de los resultados de pruebas de jarras que se llevarán a cabo, asimismo de las dosis históricas registradas en pruebas de laboratorio de los dos últimos años; las propiedades físico-químicas del agua cruda seleccionadas como entrada, son: Turbiedad, pH y conductividad, por su importancia en el proceso de la cinética de coagulación y por la facilidad de conseguir los sensores respectivos dado el caso de una futura automatización del proceso. Naturalmente, la variable de salida es la dosis óptima de sulfato de aluminio (mg/l) o eventualmente otro coagulante.

III. MATERIALES Y MÉTODOS

3.1. Lugar de ejecución.

El estudio se realizó en la Planta de tratamiento de agua potable de la Empresa de Servicios de Agua Potable y Alcantarillado Municipal de Huancayo (SEDAM HUANCAYO S.A).

3.2. Configuración de las redes neuronales artificiales

Las configuraciones de redes neuronales artificiales que se emplearon tuvieron la capacidad de predecir la dosis óptima de coagulante para determinada calidad del agua (Diamantopoulou *et al.*, 2005), los datos utilizados para su entrenamiento y prueba provienen de la *Prueba de Jarras* para determinar la dosis de coagulante en el tratamiento de agua durante el periodo de 11 meses con muestreo aleatorio diario del agua al ingreso y salida de la planta. Se propuso tres topologías de Redes Neuronales Específicas considerando las variables de entrada como pH y turbidez, color, conductividad y sólidos disueltos que intervienen en el tratamiento de agua para optimizar la dosificación y predecir su comportamiento con diversos valores de entrada.

Se utilizó configuraciones basadas en los modelos de redes neuronales de regresión generalizada (GRN) y de red neuronal de múltiples capas (MLFN); para el entrenamiento, prueba y predicción se utilizó el programa NeuralTools® ver 6.0 que maneja algoritmos de eficiencia demostrada.

La aplicación de redes neuronales artificiales en el presente estudio comprendió varias fases o etapas, las cuales se presentan en la siguiente figura 28:

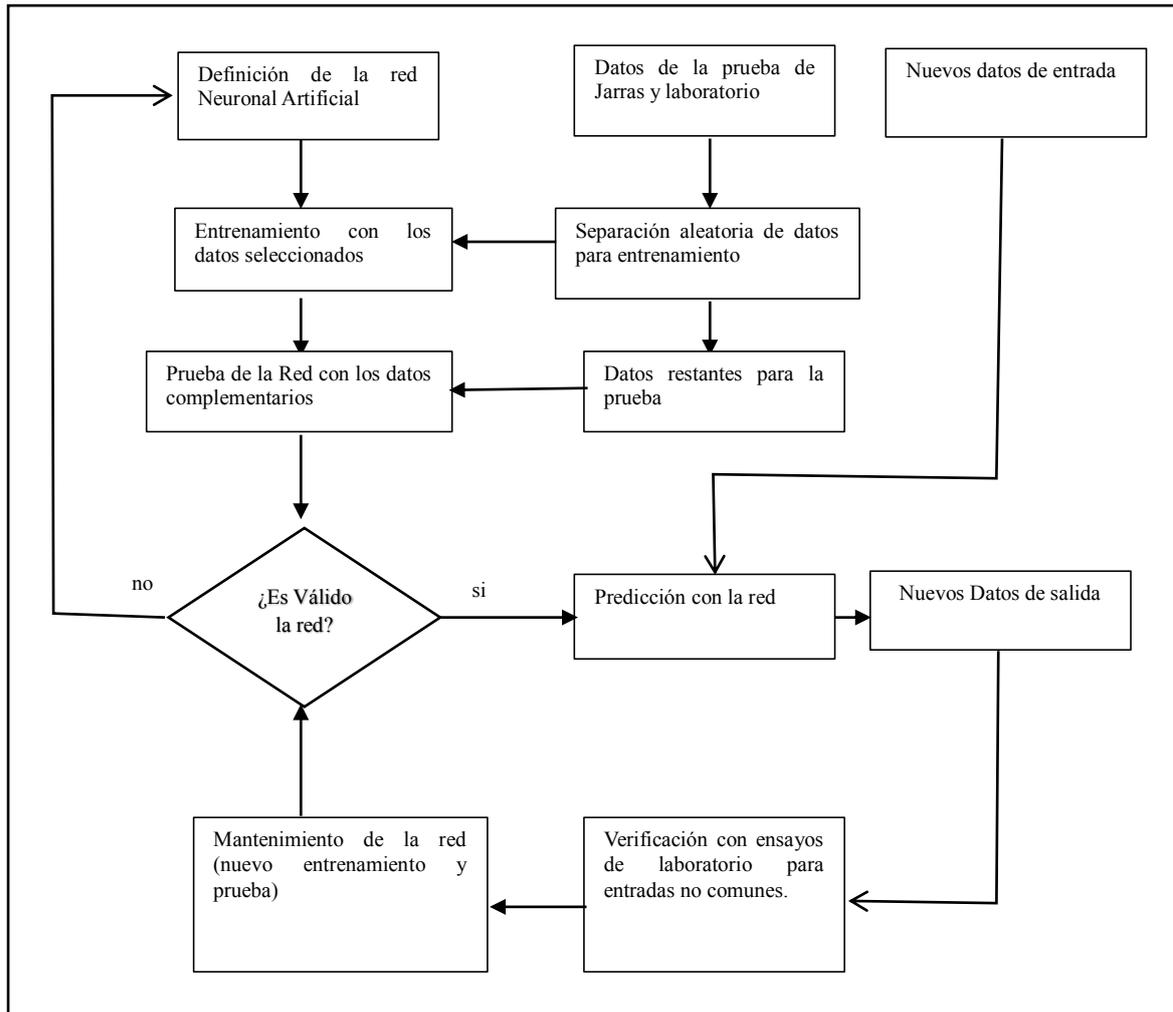


Figura 28: Metodología para la investigación

Cada uno de los pasos mostrados en la figura 28:

- Configuración de la red neuronal. Se determinó la estructura de la red asignando el número de neuronas para cada capa: entrada, oculta(s) y salida, así como también las diferentes funciones de activación que se utilizarán en las neuronas de la capa oculta y salida.
- Los datos obtenidos de la *Prueba de Jarras* y laboratorio (Anexo 01), se dividió en dos grupos de forma aleatoria, para la etapa de entrenamiento y para la etapa de prueba, las cuales al final serán contrastadas con las producidas por la red para medir su eficiencia.

- Entrenamiento de la red neuronal. En esta etapa se ejecutó el entrenamiento con un algoritmo preestablecido, para el estudio se utilizó el aprendizaje supervisado.
- Predicción de la red neuronal. La fase de predicción o utilización fue propiamente la ejecución de la estructura de la red ya entrenada y probada. Se inició cuando se presentó valores indistintos en la capa de entrada y la red fue capaz de determinar valores para la dosis óptima.
- Mantenimiento de la red neuronal. Sobre el mantenimiento se puede decir que la mayoría de las redes se entrenan y prueban para solucionar problemas dinámicos, por lo tanto es necesaria e indispensable una validación continua para garantizar una buena utilización. A medida que transcurra el tiempo podrán surgir nuevos conjuntos de datos reales aún desconocidos por la red, y de esta forma, será necesario un nuevo aprendizaje o, dependiendo del caso realizar una nueva definición.

3.2.1. Configuración de la red neuronal artificial.

Para el diseño se utilizó el programa NeuralTools® ver 6.0 que maneja algoritmos de eficiencia demostrada.

Para el proceso de aprendizaje de la red neuronal se utilizó configuraciones basado en los modelos de redes neuronales de regresión generalizada (GRN) y la red neuronal de múltiples capas (MLFN).

Para elegir la mejor configuración se tuvo en cuenta el porcentaje de error y el coeficiente de determinación estadística el cual estuvo de acuerdo al número de capas y al número de neuronas en cada una de ellas.

3.2.2. Prueba de la red neuronal artificial

Se realizaron las pruebas de las redes neuronales con los datos obtenidos en la *Prueba de Jarras* y en cada una de ellas se han obtenido precisiones que fueron desde el 95 hasta el 96,7 por ciento, bajo diferentes dosis de coagulante y diferentes condiciones físicas de entrada del agua. Para el cual, se ha utilizado la variación en el número de capas y neuronas tanto en la entrada como en la salida de la red. Las variables que se han considerado fueron: pH, alcalinidad, conductividad eléctrica y el porcentaje de sólidos.

3.3. Método *Prueba de Jarras*

Este método es un procedimiento que se utiliza comúnmente en los laboratorios. Determina las condiciones de operación óptimas generalmente en el tratamiento de agua potable. Esta prueba se utilizó para hacer variaciones en las dosis de las diferentes muestras alternando velocidades de mezclado, para el cual se utilizó un equipo especial que se describe más adelante. (Figura 29).

El análisis mediante la *Prueba de Jarras* utilizado en investigación se realizó diariamente durante once meses, en el cual se determinaron los parámetros que influyen en la cinética de las reacciones químicas en el proceso de la coagulación. El procedimiento consistió:

A. Determinación de parámetros. Se consideraron los siguientes:

- A.1. La temperatura de las muestras de agua potable en grados centígrados siguiendo el protocolo EPA 170.1 (termométrico).
- A.2. La turbiedad de las muestras de agua en NTU (unidades de turbidez nefelométricas) siguiendo el protocolo EPA Method 180.1 (nefelometría para muestras de agua potable).
- A.3. El color de muestras de agua potable en Unidades de color verdadera (UCV). De acuerdo al protocolo EPA Method 110.2 (Colorimetría-Platino –Cobalto).
- A.4. El pH de la muestra de agua (logaritmo negativo de la actividad de iones hidrogeno) de acuerdo al protocolo EPA Method 150.1 (electrométrico).

B. Realización de las *Pruebas de Jarras*. Para ello se procede del siguiente modo:

- B.1. Se llenó seis jarras con dos litros de agua cruda cada una fue colocada en su respectivo lugar en el equipo de test de jarras. Dentro de cada jarra quedó introducida una paleta del agitador.
- B.2. Se preparó el coagulante al uno por ciento en volumen diluyendo la sal.

- B.3. Se colocaron las cantidades del coagulante sulfato de aluminio en solución al uno por ciento en seis diferentes dosis (en ml) dentro de las jarras en cada vaso mediante una pipeta de acuerdo a la turbidez medida.
- B.4. Luego se inició el funcionamiento del equipo de *Prueba de Jarras* con la velocidad máxima, aplicando en forma simultánea e instantánea el coagulante a todas las jarras. Este procedimiento simuló la mezcla rápida del coagulante con el agua cruda en la planta. El tiempo que duran los agitadores en máxima velocidad fue de un minuto.
- B.5. Se disminuyó la velocidad a 40 rpm, por 10 minutos para simular el proceso de floculación. Finalmente, se apagan los agitadores y se dejaron reposar las jarras por otros 10 minutos para simular el proceso de sedimentación.
- B.6. Se tomaron muestras de todas las jarras y se analizaron la turbiedad y otros parámetros. Se seleccionó como dosis óptima aquella que produjo la menor turbidez.

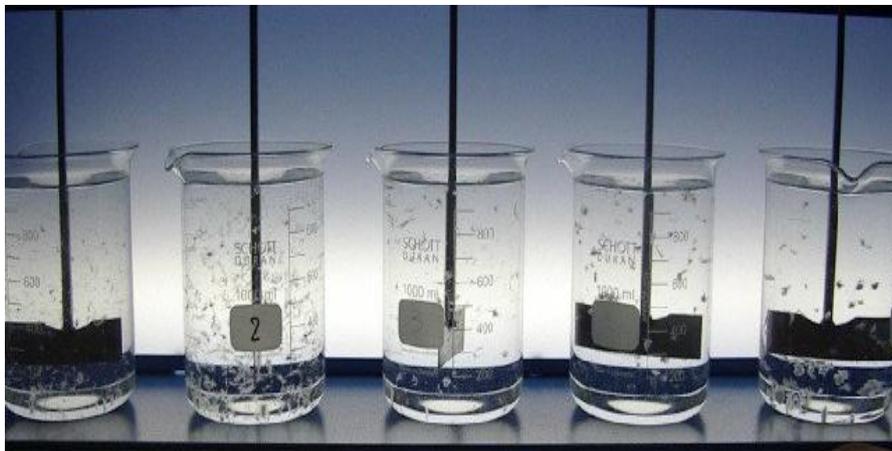


Figura 29: Equipo de Prueba de Jarras

FUENTE: SEDAM Huancayo S.A

3.4. Materiales y equipos

Se utilizaron los siguientes equipos y materiales:

- a. Equipo de pruebas que consiste en un set de seis agitadores de vasos mecánicos controlados por un aparato que regula su velocidad y una lámpara de iluminación.
- b. Seis vasos de precipitados de 2000 ml.
- c. Pipetas graduadas de 2, 5, 10,15 y 25 ml.
- d. Medidor de pH, equipo utilizado para la medición de la concentración de los iones de hidrogeno en solución ($\text{pH} = \log (\text{H}^+)$). Aun cuando el diseño y la sensibilidad de los peachímetros son variables, sus componentes esenciales son un electrodo de vidrio, un electrodo de referencia y un voltímetro calibrado para poder leer directamente en unidades de pH. Para la medición de aguas naturales y tratadas en plantas de potabilización, se requiere de una precisión de 0,05 unidades
- e. Turbidímetro, utilizado para medir la turbiedad del agua, el cual mide la intensidad de luz que pasa a través de una muestra de agua. Este equipo como unidad de medida es NTU (Unidad de turbiedad)
- f. Termómetro, instrumento utilizado para medir la temperatura, en grados centígrados.
- g. Medidor de alcalinidad, equipo que se utiliza para la medir la dureza de los carbonatos, es una medida de la capacidad del agua para neutralizar ácidos. La unidad de medida de la alcalinidad es el grado Alemán (dH o KH) (1 grado Alemán dH o KH = 17.8 mg de Carbonato de Calcio ($\text{mg CaCO}_3/\text{l}$)).

3.5. Reactivos

Los reactivos que se utilizaron son los siguientes:

- a. Soluciones Stock de 1000 ppm, de Sulfato de Aluminio. (Solución de Sulfato de Aluminio al 10 por ciento, diluida en agua destilada y se puede conservar como solución patrón hasta tres meses).
- b. Solución NaOH y HCl (1,0 N).
- c. Reactivos o Kits de análisis para pH, turbidez, color, alcalinidad y dureza.
- d. Hidróxido de Sodio NaOH (1,0 N)
- e. Agua destilada.

IV. RESULTADOS Y DISCUSIÓN

4.1. Análisis de las variables independientes consideradas en la Red Neuronal

A continuación se presenta un análisis de las variables independientes involucradas en la red y que asimismo determinaron la calidad de agua obtenida con las dosis óptimas obtenidas a nivel de laboratorio que se exponen en el Anexo 1. En todos los casos los valores de salida cumple con los límites mínimos permisible de la legislación vigente. Por ello estos datos fueron utilizados en una segunda etapa en el entrenamiento, prueba y predicción de la red.

4.1.1. Características de ingreso y salida de la turbidez

a. Comportamiento temporal de la turbidez

La turbidez tiene tres estados en su análisis cuyo comportamiento temporal.

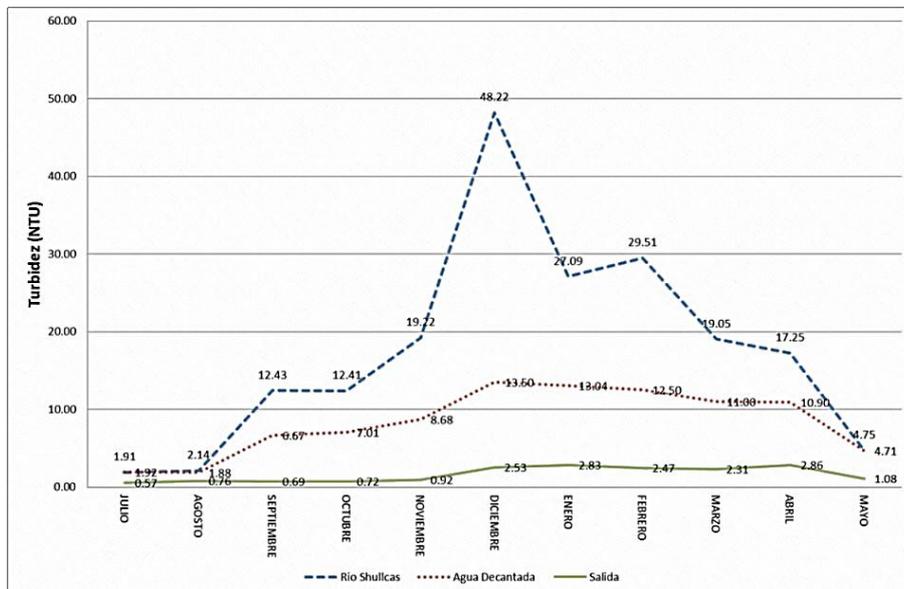


Figura 30: Evaluación promedio mensual de turbidez

Como se puede observar en la figura 30 la evidencia que la salida de esta variable se encuentra en los estándares de calidad exigida por las normas legales (5 NTU). Se evidencia que en los meses de noviembre a enero la turbidez del afluente es alta debido a las precipitaciones características del lugar.

b. Evaluación estadística de la turbidez

A partir de los datos diarios reportados en el anexo1, se deduce algunas características estadísticas de esta variable que nos evidencia la reducción a niveles permisibles aceptables en la salida del agua en promedio. (Cuadro 3).

Cuadro 3: Medidas estadísticas de la turbidez.

	Ingreso Decantada (NTU)	Salida NTU
Número de datos	335	335
Media	7,9855	1,3926
Varianza	34,6291	1,0205
desviación estándar	5,8847	1,0102
Mínimo	0,663	0,2788
Máximo	24,327	3,827
Rango	23,664	3,548
Cuartil 1	3,1286	0,6744
Mediana	6,5089	0,9000
Cuartil 3	11,4033	1,9483
Rango intercuartílico	8,2748	1,2739
Moda	14,2111	2,8444

NTU: Unidades de turbidez nefelométricas

c. Análisis gráfico del comportamiento de la turbidez

Los diagramas de cajas (box plot) presentados, muestran la disminución promedio anual de la turbidez y en el caso de salida la homogeneidad de los datos.

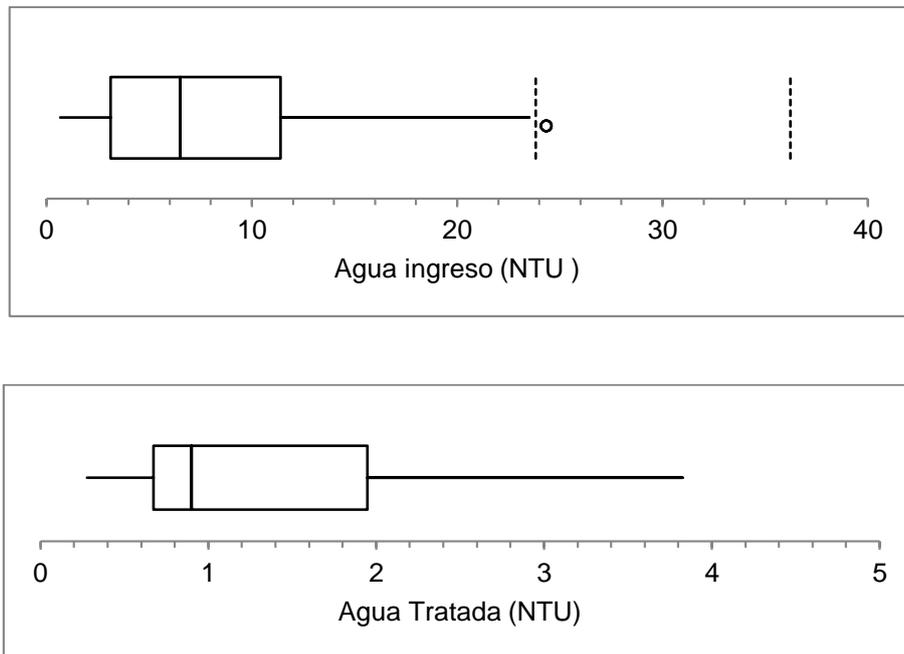


Figura 31: Diagrama de caja del comportamiento de la turbidez

4.1.2. Características de ingreso y salida del pH

a. Comportamiento temporal del pH

El pH tiene dos estados en su análisis, el de ingreso y salida de la planta, cuyo comportamiento temporal podemos observar en la figura 32. Esta variable tiene poca variabilidad y es casi constante y se encuentra en el nivel de los estándares de calidad exigida por las normas legales (6,5 – 8,5).

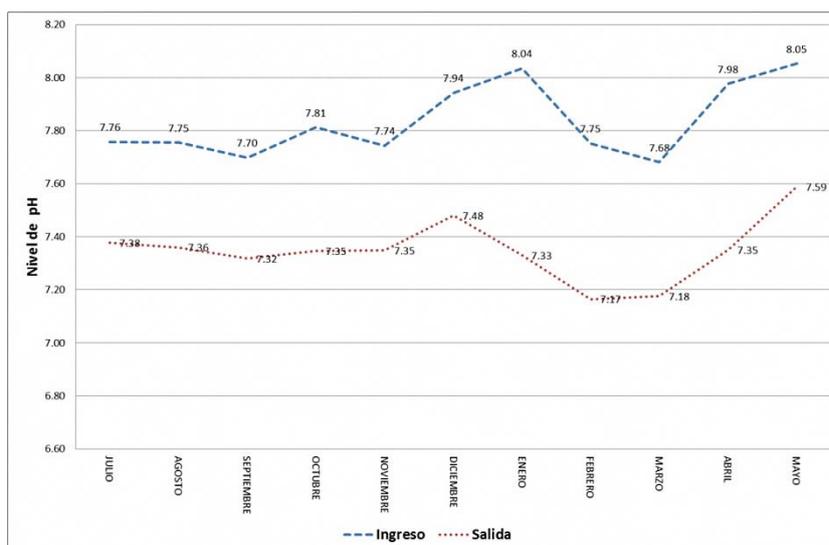


Figura 32: Evaluación promedio mensual de pH

b. Evaluación estadística del pH

A partir de los datos diarios reportados en el Anexo 1, se deduce algunas características estadísticas del pH de ingreso y salida lo que nos evidencia la permanencia en los niveles permisibles. (Cuadro 4).

Cuadro 4: Medidas estadísticas del pH

Descripción	Ingreso pH	Salida pH
Número de datos	335	335
Media	7,84	7,35
Varianza	0,08	0,07
desviación estándar	0,28	0,26
Mínimo	6,8	6,6
Máximo	8,5	7,9
Rango	1,7	1,3
Cuartil 1	7,70	7,28
Mediana	7,80	7,40
Cuartil 3	8,00	7,50
Rango intercuartílico	0,30	0,22
Moda	7,70	7,40

c. Análisis gráfico del comportamiento del pH.

Los diagramas de cajas presentados, muestran la permanencia del valor del pH tanto en el ingreso al tratamiento como en la salida.

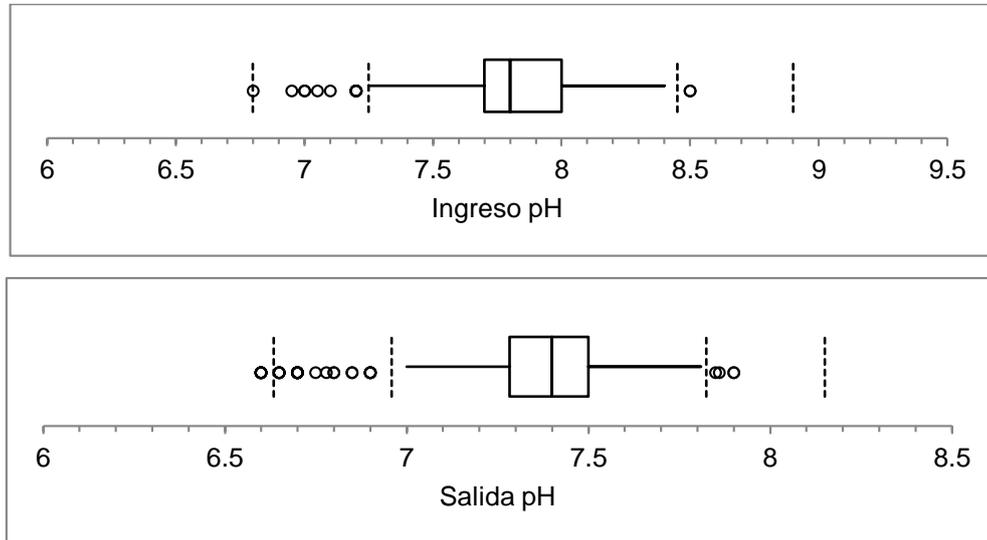


Figura 33: Diagrama de caja del comportamiento del pH

4.1.3. Características de ingreso y salida del total de sólidos disueltos (TDS)

a. Comportamiento temporal del total de sólidos disueltos (TDS)

Los sólidos disueltos totales tienen dos estados en su análisis cuyo comportamiento temporal podemos observar en la figura 34 y donde se evidencia que ambos se encuentran en los estándares de calidad por debajo de la norma legal exigida (1000 mg/l)

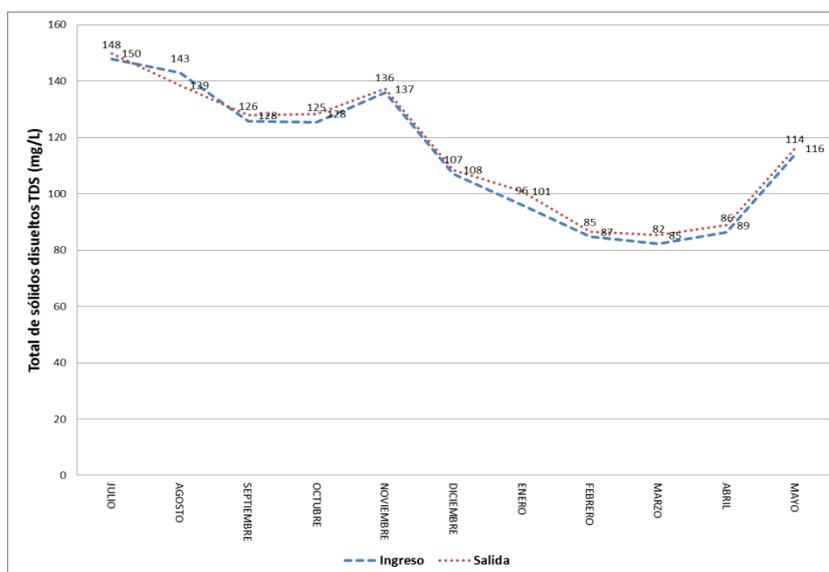


Figura 34: Evaluación promedio mensual del total de sólidos disueltos

b. Evaluación estadística del Total de sólidos disueltos (TDS)

A partir de los datos diarios reportados en el anexo 1, se deduce algunas características estadísticas de esta variable que nos evidencia la reducción a niveles permisibles aceptables en la salida del agua en promedio. (Cuadro 5).

Cuadro 5: Medidas estadísticas de los sólidos disueltos.

Descripción	Ingreso	Salida
Número de datos	335	335
Media	113,70	116,36
Varianza	836,76	807,58
desviación estándar	28,93	28,42
Mínimo	27	48,6
Máximo	183	186,67
Rango	156	138,067
Cuartil 1	91,80	93,60
Mediana	117,33	118,50
Cuartil 3	140,50	144,00
Rango intercuartílico	48,70	50,40
Moda	118,00	150,00

c. Análisis gráfico del comportamiento del total de sólidos disueltos (TDS)

Los diagramas de caja (box plot) presentados, muestran la disminución promedio anual de los sólidos disueltos y en el caso de salida la homogeneidad de los datos así como referencia a los valores extremos.

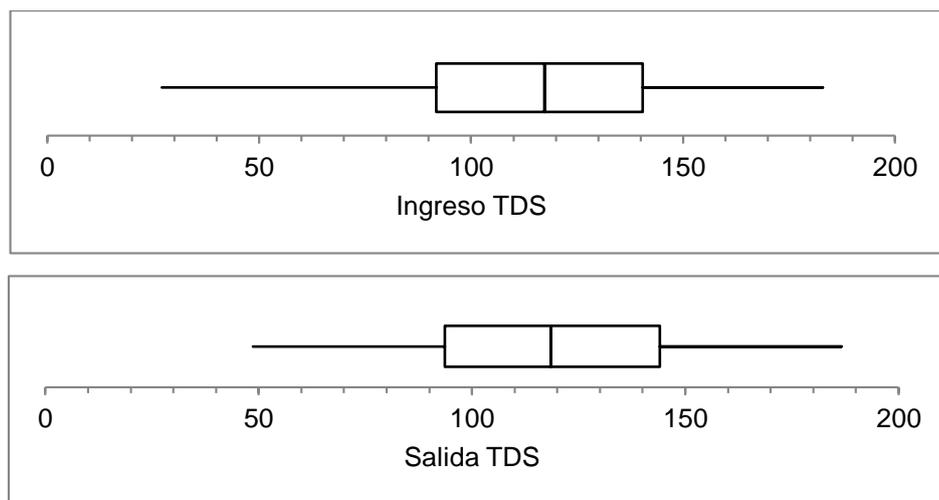


Figura 35: Diagrama de caja del comportamiento del total de sólidos disueltos

4.1.4. Características de ingreso y salida de la conductividad ($\mu\text{S}/\text{cm}$)

a. Comportamiento temporal de la conductividad ($\mu\text{S}/\text{cm}$)

La conductividad tiene dos estados en su análisis cuyo comportamiento temporal podemos observar en la figura 36 y donde se evidencia que la entrada y salida de esta variable se encuentra en los estándares de calidad exigida por las normas legales ($1500 \mu\text{S}/\text{cm}$)

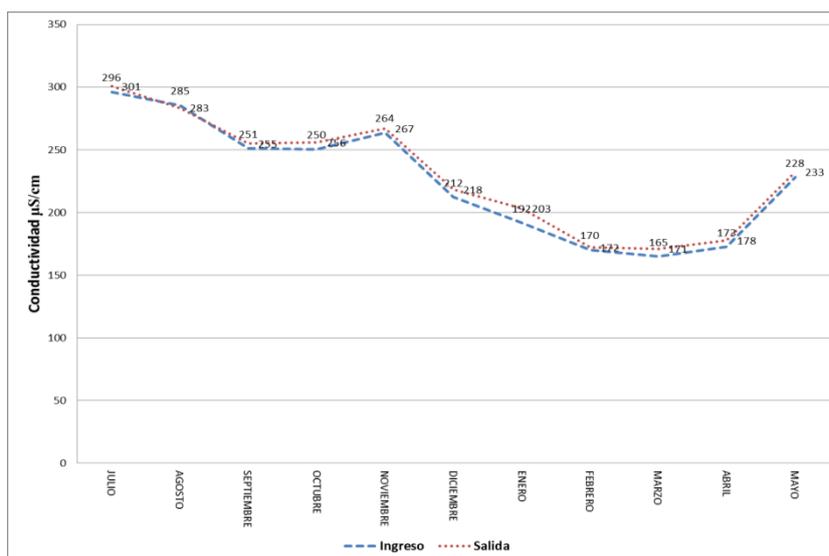


Figura 36: Evaluación promedio mensual de la conductividad eléctrica

b. Evaluación estadística de la conductividad ($\mu\text{S}/\text{cm}$)

A partir de los datos diarios reportados en el Anexo 1, se deduce algunas características estadísticas de esta variable que nos evidencia el rango y la estabilidad de la salida en niveles por debajo de los permisibles legales. (Cuadro 6).

Cuadro 6. Medidas estadísticas de conductividad.

	Ingreso Conductividad	Salida conductividad
Número de datos	335	335
media	226,55	231,16
varianza	3 208,80	3 160,02
desviación estándar	56,65	56,21
mínimo	54,1	97,2
máximo	364,5	373
Rango	310,4	275,8
Cuartil 1	183,90	186,70
mediana	235,00	236,00
Cuartil 3	281,00	285,25
Rango intercuartílico	97,10	98,55
Moda	146,40	300,00

c. Análisis gráfico del comportamiento de la conductividad ($\mu\text{S}/\text{cm}$)

Los diagramas de caja (box plot) presentados, muestran la estabilidad promedio de la conductividad de salida del agua tratada contrastando con el de la entrada.

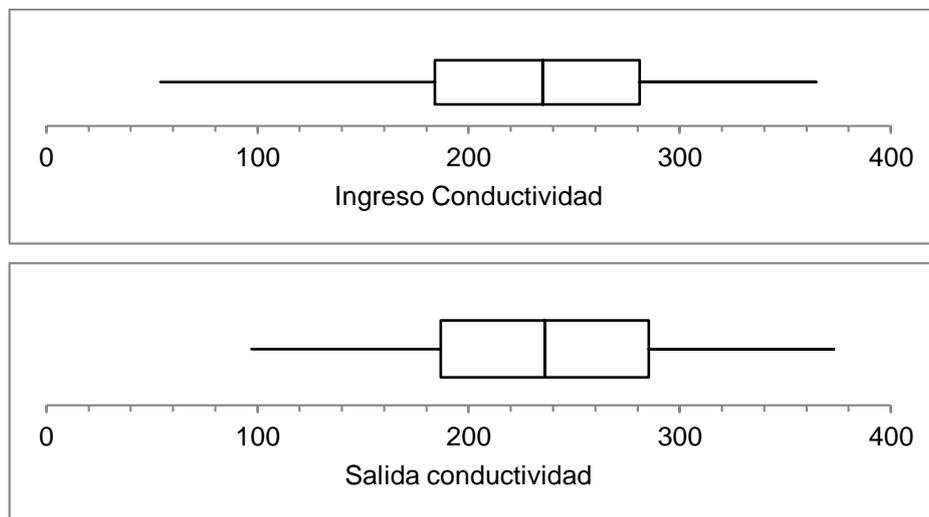


Figura 37: Diagrama de caja del comportamiento de la conductividad

4.1.5. Características de ingreso y salida del color (UCV).

a. Comportamiento temporal del color (UCV).

El color es una característica organoléptica y en el análisis tiene dos estados cuyo comportamiento temporal podemos observar en la figura 37, donde se evidencia que la salida de esta variable está muy por debajo de los estándares de calidad exigida por las normas legales (29 UCV).

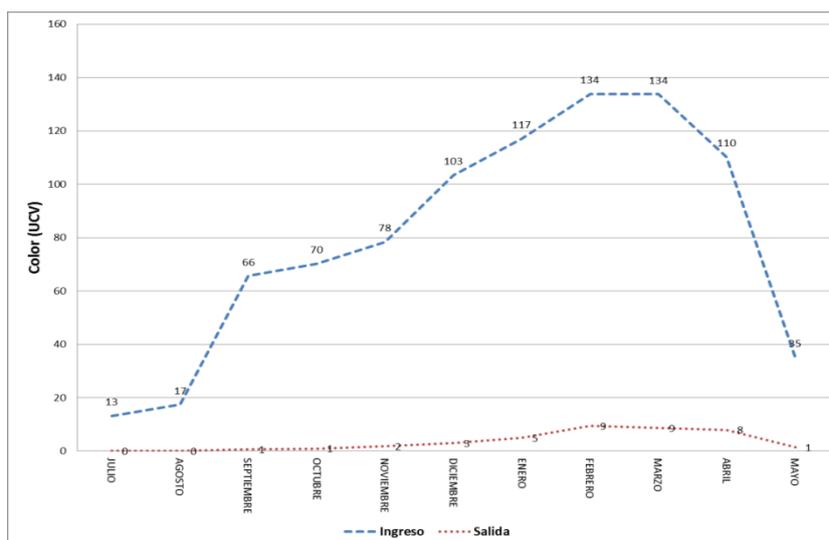


Figura 37. Evaluación promedio mensual del comportamiento del color

b. Evaluación estadística del color (UCV).

A partir de los datos diarios reportados en el anexo1, se deduce algunas características estadísticas de esta variable que nos evidencia la reducción a niveles menores a los permisibles legales en la salida del agua en promedio. (Cuadro 7).

Cuadro 7: Medidas estadísticas del color de agua.

Descripción	Ingreso COLOR	Salida COLOR
Número de datos	335	335
Media	76,62	3,49
varianza	4 077,99	24,75
desviación estándar	63,86	4,98
mínimo	5	0
máximo	390	19
Rango	385	19
Cuartil 1	20,50	0,00
mediana	59,00	1,00
Cuartil 3	119,25	6,00
Rango intercuartílico	98,75	6,00
moda	178,00	0,00

c. Análisis gráfico del comportamiento del color (UCV).

Los diagramas de caja (box plot) presentados, muestran la estabilidad promedio del color en la salida del agua tratada contrastada con la del ingreso.

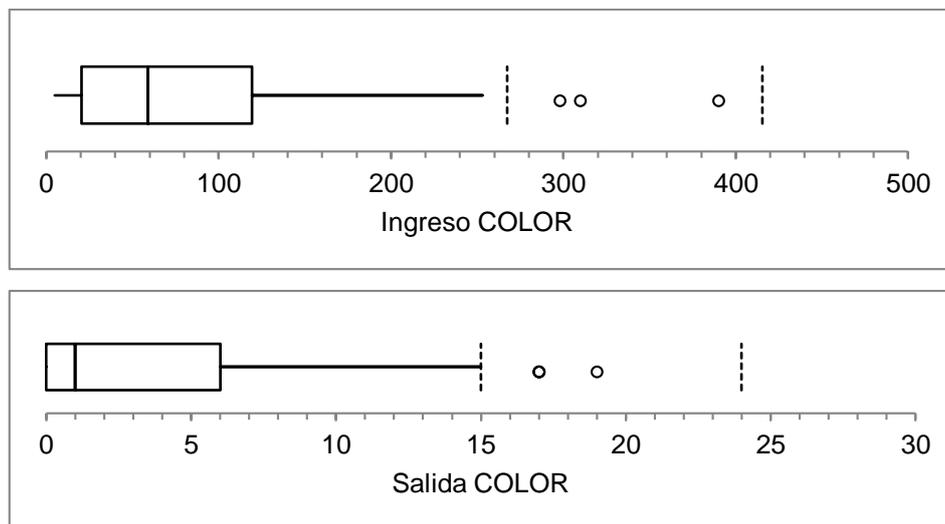


Figura 38: Diagrama de caja del comportamiento del color (UCV)

4.2. Configuración de la arquitectura de la red óptima

El software NeuralTools facilitó la selección de una configuración de red al ofrecer una búsqueda de mejor red, para ello en cada caso, la red neuronal propuesta se entrena con parte de los datos validados y posteriormente se hace la prueba con los datos restantes. Una vez hecha la prueba se puede realizar predicciones para el cálculo de dosis óptima de coagulante con datos independientes aleatorios con valores dentro del rango histórico entrenado. Estas configuraciones se valida estadísticamente de acuerdo a la distribución de errores y al índice de determinación que produce la salida de la red versus al dato histórico de dosis óptima. Para el estudio se incluyeron las redes GRN y las redes MLFN con cuentas de distintos nodos en la capa oculta, así se logró disponer de modelos de los cuales se selecciona el mejor.

4.2.1. Red neuronal con una capa oculta de cinco nodos.

La arquitectura de esta red consta de tres capas una de entrada con cinco neuronas, una capa oculta de cinco neuronas y una capa salida de una neurona como podemos observar en la figura 39.

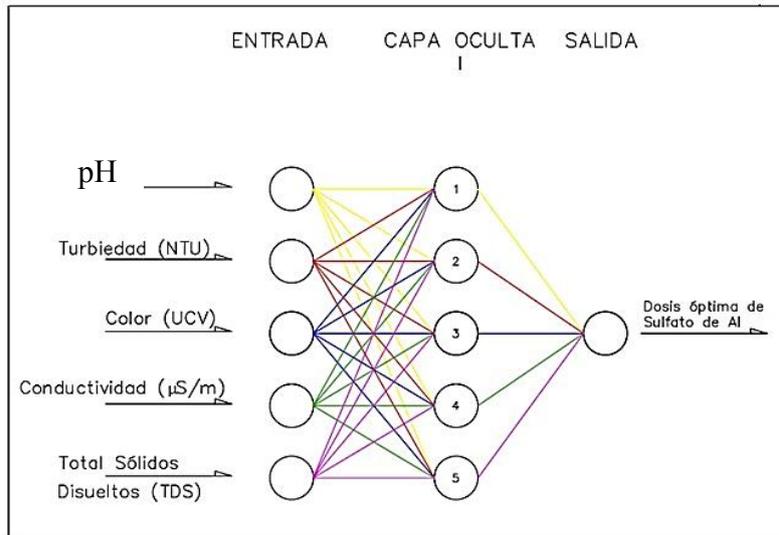


Figura 39: Configuración de red con tres capas (una oculta de cinco neuronas)

a. Análisis del entrenamiento de la red cinco nodos

La prueba de entrenamiento se realiza con 134 de los 345 datos del Anexo 01, produciendo los siguientes resultados para la dosis óptima: (Cuadro 8).

Cuadro 8: Resumen del entrenamiento de la red con una capa oculta de cinco nodos.

Característica	Descripción
Configuración	Predicción lineal
Variables numéricas independientes	(Agua Decantada NTU, Salida NTU, Ingreso COLOR, Salida COLOR, Ingreso pH, Salida pH, Ingreso Conductividad, Salida conductividad, Ingreso TDS, Salida TDS)
Variable dependiente	Dosis óptima coagulante (Sulfato de aluminio en ppm)
Entrenamiento	
Número de casos	134
Porcentaje de predicciones incorrectas (30 por ciento tolerancia)	11,194
Error cuadrático medio	2,916
Error absoluto medio	2,342
Desviación estándar de error absoluto	1,737

En la figura 40 se muestra el análisis de regresión con el comportamiento de los resultados del entrenamiento de esta red neuronal para la dosis óptima de los datos producidos por la red frente a los datos reales históricos calculados en el laboratorio en ella podemos observar el índice de determinación de 0,825.

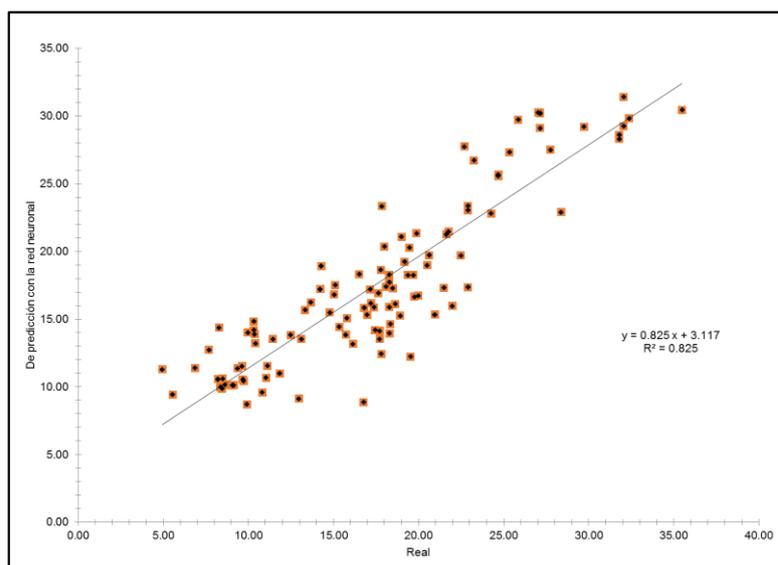


Figura 40: Regresión lineal de entrenamiento de red con 3 capas (una oculta)

b. Análisis de la prueba de la red cinco nodos

Los datos de la prueba se realizan con los 201 datos restantes cuyos resultados se consignan en el siguiente Cuadro 9.

Cuadro 9: Resumen de la Prueba con la red de una capa con cinco nodos

Característica	Valor
Número de casos	201
Porcentaje de predicciones incorrectas (30 por ciento de tolerancia)	14,4279
Error cuadrático medio	3,364
Error absoluto medio	2,575
Desviación estándar de error absoluto	2,164

En la figura 40 se muestra el comportamiento del error residual de los datos producidos por la red frente a los datos reales históricos calculados en el laboratorio, en ella podemos observar el índice de determinación de 0,731.

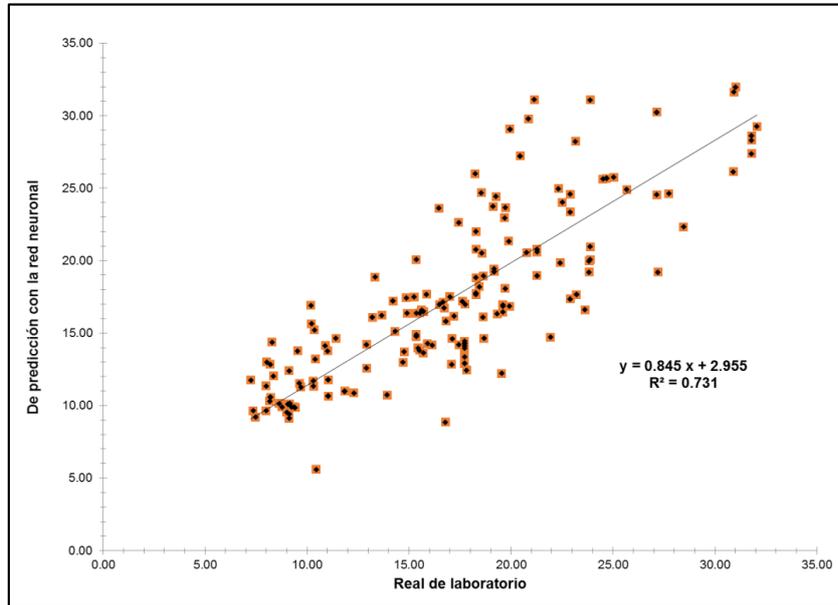


Figura 40: Regresión lineal de la prueba de red con tres capas (una oculta)

4.2.2. Red neuronal con dos capas ocultas (6 y 5 neuronas).

La arquitectura de esta red consta de cinco capas una de entrada con cinco neuronas, una primera capa oculta de seis neuronas, una segunda capa oculta de cinco neuronas y una capa salida de una neurona de la dosis óptima como podemos observar en la siguiente figura 41.

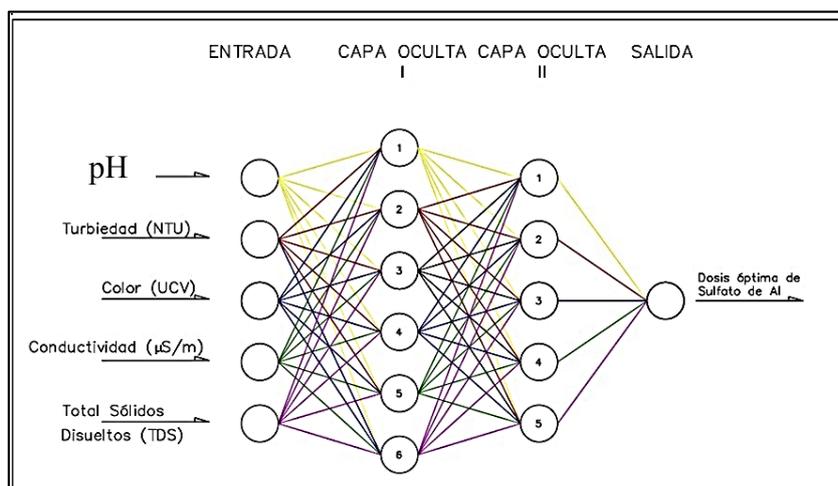


Figura 41: Configuración de red neuronal con cuatro capas (dos ocultas)

a. Análisis del entrenamiento de la red dos capas ocultas.

A continuación se presenta un resumen de los resultados con dos capas ocultas.

Cuadro 10: Resumen del entrenamiento de la red con dos capas ocultas

Característica	Descripción
Configuración	Predicción lineal
Variables numéricas independientes	(Agua Decantada NTU, Salida NTU, Ingreso COLOR, Salida COLOR, Ingreso pH, Salida pH, Ingreso Conductividad, Salida conductividad, Ingreso TDS, Salida TDS)
Variable dependiente	Dosis óptima coagulante (Sulfato de aluminio en ppm)
Entrenamiento	
Número de casos	134
Porcentaje de predicciones incorrectas (30 por ciento de tolerancia)	11,094
Error cuadrático medio	2,916
Error absoluto medio	2,342
Desviación estándar de error absoluto	1,537

En la figura 42 se muestra el análisis de regresión con el comportamiento de los resultados del entrenamiento de esta red neuronal para la dosis óptima de los datos producidos por la red frente a los datos reales históricos calculados en el laboratorio en ella podemos observar el índice de determinación de 0,865.

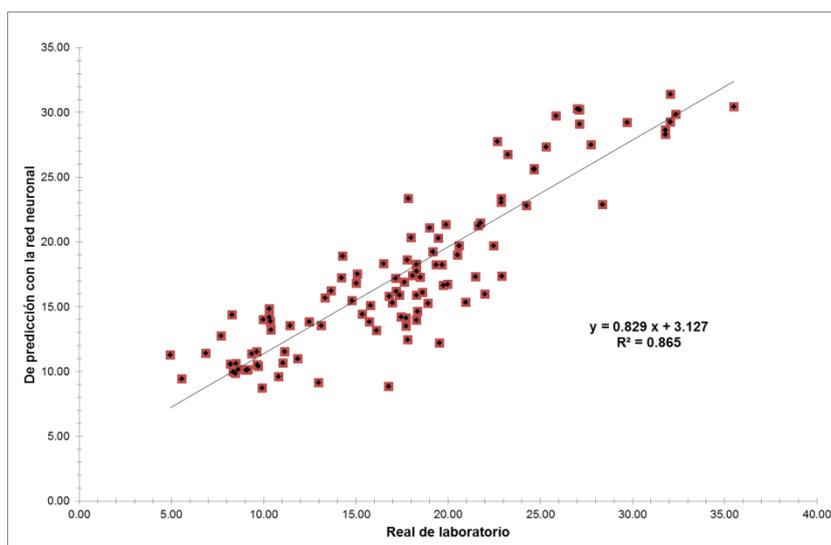


Figura 42: Regresión lineal de entrenamiento de red con cuatro capas (dos ocultas)

b. Análisis de la prueba de la red de dos capas ocultas

Los datos de la prueba se realizan con los 201 datos restantes cuyos resultados se consignan en el siguiente Cuadro 11.

Cuadro 11: Resumen de la Prueba con la red de una capa

Característica	Valor
Número de casos	201
Porcentaje de predicciones incorrectas (30 por ciento de tolerancia)	14,3179
Error cuadrático medio	3,364
Error absoluto medio	2,575
Desviación estándar de error absoluto	2,094

En la figura 43 se muestra el comportamiento del error residual de los datos producidos por la red frente a los datos reales históricos calculados en el laboratorio, en ella podemos observar el índice de determinación de 0,781.

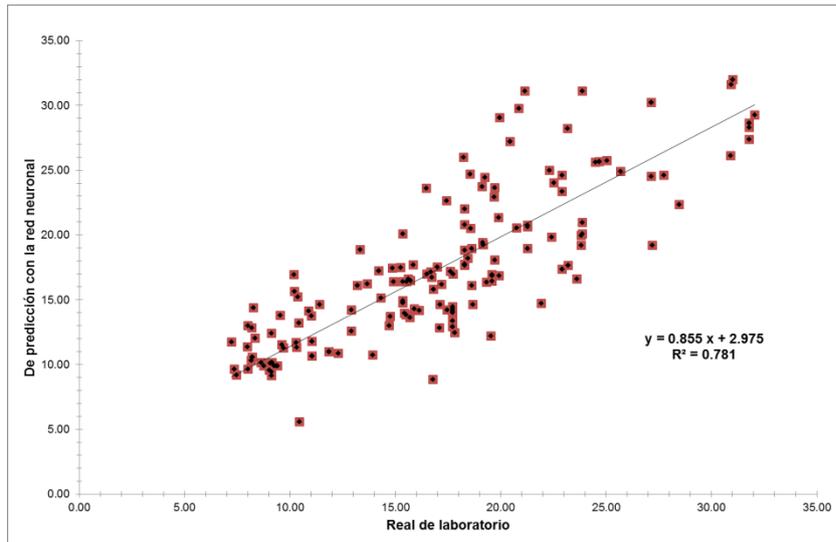


Figura 43: Regresión lineal de la prueba de red con cuatro capas (dos ocultas)

4.2.3. Red neuronal con una capa oculta de regresión generalizada (GRN)

La arquitectura de esta red consta de cuatro capas una de entrada con cinco neuronas, dos capas ocultas (en la primera se adiciona una neurona por cada caso entrenado y en la segunda oculta dos neuronas receptoras para regresión) y una capa salida de una neurona como podemos observar en la figura 44.

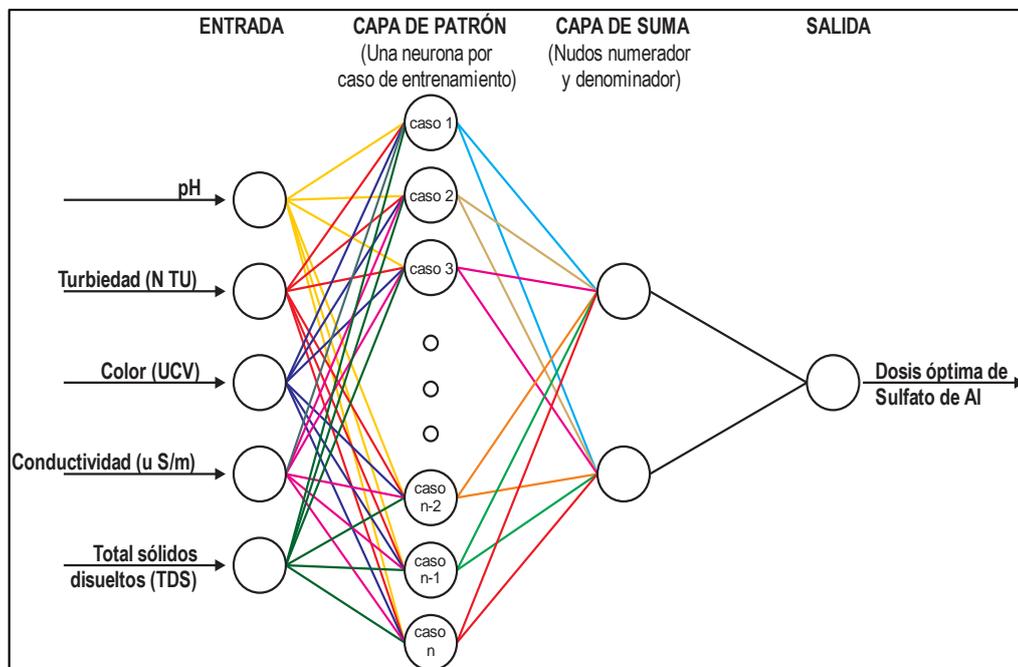


Figura 44: Configuración de la red neuronal de regresión generalizada (GRN)

a. Análisis del entrenamiento de la red de regresión generalizada (GRN)

La prueba de entrenamiento se realiza con 134 de los 345 datos del anexo 01, produciendo los siguientes resultados para la dosis óptima: (Cuadro 12).

Cuadro 12: Resumen del entrenamiento con la red de regresión generalizada (GRN)

Característica	Descripción
Configuración	Predicción lineal
Variables numéricas independientes	(Agua Decantada NTU, Salida NTU, Ingreso COLOR, Salida COLOR, Ingreso pH, Salida pH, Ingreso Conductividad, Salida conductividad, Ingreso TDS, Salida TDS)
Variable dependiente	Dosis óptima coagulante (Sulfato de aluminio en ppm)
Entrenamiento	
Número de casos	134
Porcentaje de predicciones incorrectas (30 por ciento de tolerancia)	3,7313
Error cuadrático medio	1,235
Error absoluto medio	0,7401
Desviación estándar de error absoluto	0,9882

En la figura 45 se muestra el análisis de regresión con el comportamiento de los resultados del entrenamiento de esta red neuronal para la dosis óptima de los datos producidos por la red frente a los datos reales históricos calculados en el laboratorio en ella podemos observar el índice de determinación de 0,969.

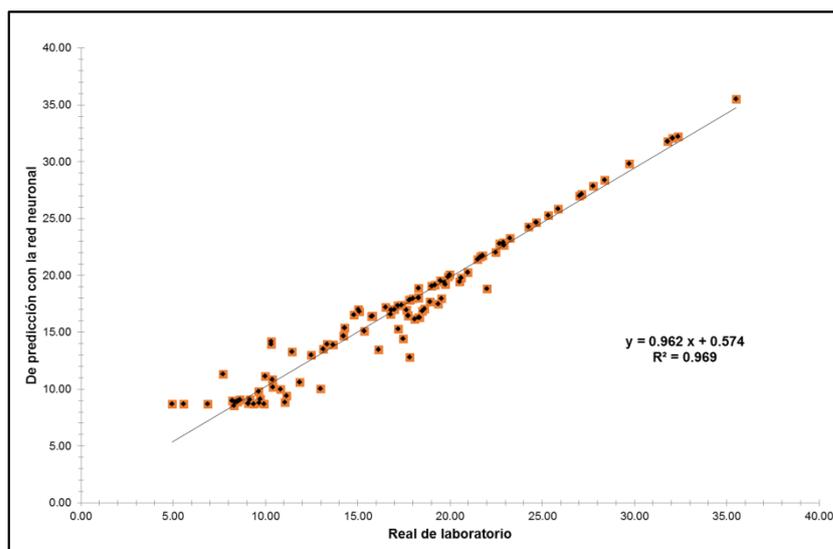


Figura 45: Regresión lineal de entrenamiento de red de regresión generalizada GRN (dos ocultas)

b. Análisis de la prueba de la red de regresión generalizada

Los datos de la prueba se realizan con los 201 datos restantes cuyos resultados se consignan en el (Cuadro 13):

Cuadro 13: Resumen de la prueba con la red de regresión generalizada

Característica	Valor
Número de casos	201
Porcentaje de predicciones incorrectas (30 por ciento tolerancia)	8,9552
Error cuadrático medio	2,928
Error absoluto medio	1,827
Desviación estándar de error absoluto	2,288

En la figura 46 se muestra el comportamiento del error residual de los datos producidos por la red frente a los datos reales históricos calculados en el laboratorio para la prueba, en ella podemos observar el índice de determinación de 0,852.

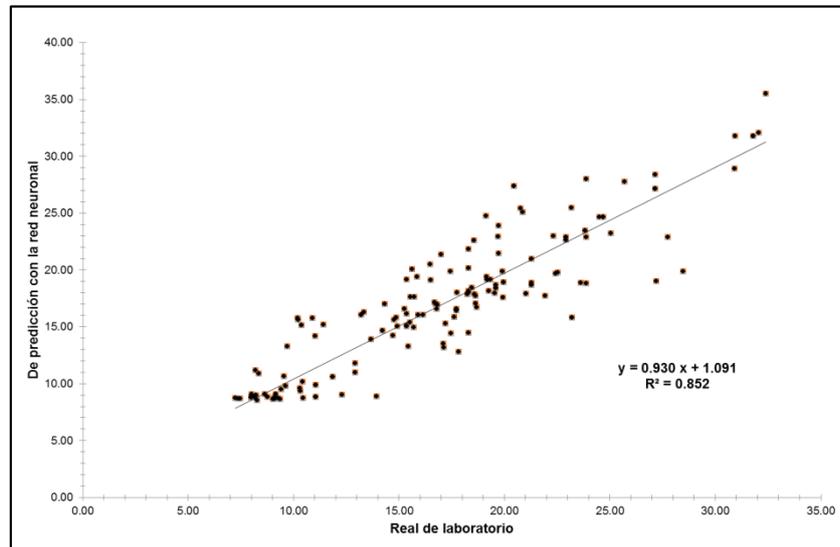


Figura 46: Regresión lineal de prueba de red de regresión generalizada GRN (dos ocultas)

4.3. Evaluación de la red neuronal óptima

De acuerdo a los resultados producidos por las tres configuraciones presentadas se realiza la evaluación mostrada en el cuadro siguiente:

Los resultados de los tres mejores modelos entrenados se presentan en el (Cuadro 14).

Cuadro 14: Evaluación de la mejor configuración de la red neuronal

Configuración de la Red Neuronal.	ENTRENAMIENTO			PRUEBA		
	Porcentaje Predicción incorrecta	Desviación estándar (Error residual)	Índice determinación (correlación)	Porcentaje Predicción incorrecta.	Desviación estándar (Error residual)	Índice determinación (correlación)
Tres capas (una oculta de 5 neuronas)	11,1940	1,737	0,825	14,4279	2,164	0,731
Cuatro capas (dos ocultas de 6 y 5 neuronas)	11,0940	1,537	0,865	14,31	2,094	0,781
Tres capas (una oculta de n neuronas de regresión generalizada)	3,7313	0,9882	0,969	8,9552	2,288	0,852

Se observa que la mejor configuración de red neuronal por tener el menor porcentaje de predicciones incorrectas en las fases de entrenamiento y prueba así como el mayor índice de determinación es la Red de tres capas de Regresión generalizada (la primera de cinco neuronas integradas de las variables independientes, una oculta de 124 neuronas autoformada por cada entrenamiento y una capa de salida de una neurona que es la dosis óptima del coagulante de Sulfato de Aluminio). Su índice de determinación en el entrenamiento de 96,9 por ciento nos indica una correlación lineal de 98,4 por ciento cercana al 100 por ciento entre el pronóstico de la red neuronal y las pruebas del laboratorio.

4.4. Impactos de las variables en el modelo seleccionado de regresión generalizada

Los factores que han sido ingresados al modelo tienen distintos pesos o prioridades de acuerdo a la homogeneidad o variabilidad de los datos, si los datos fueran constantes o casi uniformes su influencia en el modelo es menor. Como podemos observar en el Cuadro 15

los sólidos disueltos totales y la turbidez son los factores de mayor relevancia en el modelo ya que su variabilidad debida a las precipitaciones es alta. (Cuadro 15).

Cuadro 15: Análisis de impacto de variables independientes

Variable	Porcentaje en el modelo óptimo
Ingreso COLOR	39,8478
Salida NTU	24,3274
Salida pH	16,9261
Agua Decantada NTU	10,5127
Ingreso pH	2,3641
Ingreso Conductividad	1,8325
Ingreso TDS	1,5993
Salida TDS	1,4119
Salida conductividad	1,0521
Salida COLOR	0,1260

V. CONCLUSIONES

1. Según las la evaluación de las configuraciones de redes propuestas; la Red Neuronal Artificial de Regresión Generalizada (GRN) presenta mejor rendimiento en sus resultados de entrenamiento y prueba de la dosis óptima de coagulante de sulfato de aluminio en el tratamiento de agua potable aplicando distintos parámetros físicos y químicos de entrada, siendo el porcentaje de error de 3,73 por ciento en el entrenamiento y su índice de determinación en el entrenamiento de 96,9 por ciento, lo cual nos indica una correlación de 98,4 por ciento cercana al 100 por ciento entre el pronóstico de la red neuronal y las pruebas del laboratorio reales.
2. El análisis de impacto e importancia de los factores de entrada en la red que influyen en la prueba, entrenamiento y predicción de la Red Neuronal de Regresión Generalizada (GNR) son en orden de prioridad: el color, la turbidez y el pH, esto debido a su variabilidad en el registro histórico.
3. En las distintas pruebas realizadas a las tres configuraciones de red propuestas, se confirma que las variables de entrada que tiene menor varianza presentan menos impacto en los resultados de entrenamiento y predicción de los modelos.
4. La predicción de dosificación de coagulante calculada en tiempo real por la configuración de la Red Neuronal Artificial de Regresión Generalizada (GRN) permite tomar decisiones rápidas y con errores menores al cuatro por ciento ante cambios inesperados de turbiedad y/o pH que se puedan presentar cuando el afluente se altera debido a las precipitaciones fluviales intempestivas que caen en la zona.
5. La red neuronal seleccionada para el cálculo de la dosis óptima de coagulante (Sulfato de Aluminio) permite un continuo aprendizaje y disminución del error con nuevos registros que se puedan ingresar a la base de datos de los parámetros de entrada producidos con la *Prueba de Jarras*.
6. La *Prueba de Jarras* es un método de laboratorio que permite validar la dosis óptima de coagulante en el tratamiento de agua potable para consumo humano, cuyos datos permiten probar, entrenar y validar los resultados ofrecidos por la Red de Neuronal Artificial.

VI. RECOMENDACIONES

1. Los distintos modelos de redes neuronales pueden probarse constantemente y entrenar continuamente con mayores datos históricos y el modelo ser reconfigurado para mejorar su asertividad y permitirá hacer predicciones de dosis óptima con nuevas entradas de las variables independientes, prescindiendo en momentos críticos de la *Prueba de Jarras*.
2. Se debe considerar que los resultados de mejora en la coagulación también es debido al tiempo de la mezcla y a la naturaleza de las reacciones involucradas en la coagulación, se deduce que para que ocurra la neutralización de la carga, es imperativo que los coagulantes sean difundidos en la masa de agua tan rápido como sea posible (menos de 0,1 segundo), para que los productos que se desarrollan entre 0,01 y un segundo produzcan la desestabilización del coloide. Por el contrario, para la coagulación de barrido, la formación del hidróxido se produce en un rango de uno a siete segundos, por lo que es evidente que no es de crucial importancia disponer de tiempos de dispersión muy cortos o de altas intensidades de mezcla
3. Diseñar un sistema automatizado control mediante redes neuronales con aprendizaje y entrenamiento permanente es recomendable para la segunda fase y estaría orientada a la utilización de sensores para el ingreso y salida de las variables del proceso.
4. Desarrollar nuevos modelos de red neuronales involucrando otras variables del agua cruda previamente analizadas como la alcalinidad, dureza y velocidad de mezclado de manera que pueda mejorar la calidad de agua producida.
5. Se debe proponer nuevas configuraciones de Red neuronal Artificial considerando la alcalinidad del agua que es una variable crítica en el comportamiento de la formación de los flocs.

VII. REFERENCIAS BIBLIOGRÁFICAS

1. Amirtharajah, A. 1989. The mechanisms of coagulation. Seminario Nacional sobre Coagulación y Filtración Directa. Universidad de São Paulo. Escuela de Ingeniería de San Carlos.
2. ANA (Autoridad Nacional del Agua, PE). 2013. Situación actual y perspectivas en el sector agua y saneamiento en el Perú. Seminario de “Tecnología alemana en el rubro de Agua y Saneamiento.
3. Aviles, M. y Tirado, M. 2010. Remoción de arsénico por Coagulación-Floculación a Nivel Domiciliario. Instituto Mexicano de Tecnología del agua.
4. Badalians, G.; Gholikandi, Delnavaz, M. y Riahi, R. 2011. Use of Artificial Neural Network for Prediction of Coagulation/Flocculation process by pac in Water Treatment Plant. *Environmental Engineering and Management Journal*. 10(11): 1719-1725.
5. Cauwenberghs, G. 1993. A fast stochastic Error-Descent Algorithm for supervised learning and optimization. En *Advances in Neural Information Processing Systems*, S. J. Hanson, J. D. Cowan, C. L. Giles (eds). Morgan Kaufmann, San Mateo, CA. p. 244-251.
6. CEPIS (Centro Panamericano de Ingeniería Sanitaria y Ciencias del Ambiente, PE). 2004. Tratamiento de agua para consumo humano. Plantas de filtración rápida. Teoría. Lima.
7. Chinrungrueng, C. 1988. Analysis of simple neural networks. Master's Report. Computer Science Department, University of California at Berkeley.
8. Chinrungrueng, C. 1993. Evaluation of Heterogeneous Architectures of Artificial Neural Networks. Technical Report. Computer Science Department, University of California at Berkeley.
9. Cohen, J. M. y Hannah, S. A. 1971. Coagulation and flocculation. En: *Water Quality and Treatment. A Handbook of Public Water Supplies*. Tercera edición Capítulo 3
10. De Falco, I.; Della, A.; Natale, P. y Tarantino, E. 1997. Artificial Neural Networks Optimization by means of Evolutionary Algorithms. En: *Soft Computing in Engineering Design and Manufacturing*. P; Chawdhry, R; Pant, R; Roy eds. Springer Verlag.
11. Del Brio, B.; Sanz, A. 2002. *Redes neuronales y Sistemas difusos*. Editorial Alfaomega. Mexico.

12. Diamantopoulou, M.; Papamichail D; Antonopoulos, V. 2005. The Use of a Neural Network Technique for the Prediction of Water Quality Parameters. *Epeovtt / Operational Research*. En: *An International Journal* 5(1): 115-125.
13. Durdu, O. 2009. A hybrid neural network and ARIMA model for water quality time series prediction. *Engineering Applications of Artificial Intelligence*, 32:1025-1034.
14. El agua potable. 2014. Tratamiento de Agua (en línea). Consultado 20 jun. 2014. Disponible en http://www.elaguapotable.com/tratamiento_del_agua.htm
15. Fritsch, J. 1996. Modular Neural Networks for Speech Recognition. Tesis Mg Sc. Carnegie Mellon University.
16. Funahashi, KI. 1989. On the approximate realization of continuous mappings by neural networks. En: *Neural Networks*, 2: 183-192.
17. García Martínez, R; Pasquini, D y Servente, M. 2003 *Sistemas Inteligentes*. En: Nueva Librería.
18. Griffiths, KA y Andrews, RC. 2011. Application of Artificial Neural Networks for Filtration Optimization. Eds. *Journal of Environmental Engineering* © ASCE/ November 2011. P. 1040 – 1047.
19. Gurney, K. 1997. *Neural Nets*. CRC Press.
20. Heddam, S; Bermad, A y Dechemi, N. 2011. Application of Radial – Basis Function and Generalized Regression Neural Networks for Modeling of Coagulant Dosage in Drinking Water – Treatment Plant: Comparative Study. Eds. *Journal of Environmental Engineering* © ASCE / December 2011. p. 1209 -2014.
21. Hornik, K; Stichcombe, M y White, H. 1989. Multilayer feedforward networks are universal approximators. En: *Neural Network*, 2(5): 359 – 366
22. *Inteligencia Artificial*. 2015. Los Fundamentos de la Inteligencia artificial (en línea). Consultado 20 jun. 2015. Disponible en inteligenciaartificialkarlacevallos.wordpress.com.
23. Isasi Viñuela, P; Galván León, IM. 2004. *Redes Neuronales Artificiales. Un enfoque Práctico*. Prentice Hall.
24. Lee, W. 2013. *Tecnología de Coagulación-Floculación*. Consultado 10 de ago. 2016. Disponible en www.agualatinoamerica.com.
25. DIGESA (Dirección General de Saneamiento Ambiental, PE). 2008. Informe de Vigilancia de la Calidad de los Recursos Hídricos – Registro de datos. Dirección de Ecología y Protección del Ambiente – DEPA de la Autoridad Sanitaria. DIGESA/DEPA/JMRR/24/04/2008. P. 1- 6.

26. MINAM (Ministerio del Ambiente, PE). 2013. Plan de Gestión de Recursos Integrados de Recursos Hídricos de la Subcuenca del Río Shullcas. Proyecto de adaptación al impacto del Retroceso Acelerado de Glaciares en los Andes Tropicales. PRAA Perú. Edición SENAMHI.
27. Nascimento, C. 1994. Artificial Neural Networks in Control and Optimization. PhD Thesis. Manchester, University of Manchester, Institute of Science and Technology (UMIST), Control Systems Centre, Manchester, United Kingdom.
28. Saint-Gerons, A. 2004. Desarrollo de una red neuronal para estimar el oxígeno disuelto en el agua a partir de instrumentación de E:D:A:R: Jornadas de automática. España.
29. Sanger, T. 1989. Optimal Unsupervised Learning in Feedforward neural networks. En *Neural Networks*, 2: 459-473.
30. Specht, D. 1990. Probabilistic Neural Networks, *Neural Networks*, 3: 109-118
31. Specht, D. 1991. A General Regression Neural Network, *IEEE Transactions on Neural Networks*, 2: 568-576).
32. SUNASS (Superintendencia Nacional de Servicios de Saneamiento, PE). 2014. Proyecto Tarifario: Determinación de la Formula Tarifaria, Estructura Tarifaria y Metas de Gestión Aplicable a la Empresa Prestadora de Servicios de Agua y Alcantarillado SEDAM Huancayo S.A.
33. Tezel, G; Yel, E y Sinan, RK. 2009. Artificial Neural Network (ANN) Model for Domestic Wastewater Treatment Plant Control. Selcuk University, Computer Engineering Department, Kampus. Konya/TURKEY.
34. Valentin, N y Denoeuxb, T. 2000. A Neural network – based software sensor for coagulation control in a water treatment plant. Université de Technologie de Compiègne, UMR CNRS 6599 Heudiasyc. Compiègne, France, BP 20529, F – 60205.
35. WHO (World Health Organization). 2013. Water sanitation health. 10 aspectos relativos a la aceptabilidad. (en línea). Consultado 18 de abril del 2013. Disponible en www.who.int/water_sanitation_health/dwq/gdwq3_es_10.pdf
36. Yao, X. 1993. Evolutionary Artificial Neural Networks. En *International Journal of Neural Systems*. 4: 203-222.
37. Yao, X. 1995. Evolutionary Artificial Neural Networks. En *Encyclopedia of Computer Science and Technology*, Kent, A., J. G. Williams(eds), Marcel Dekker Inc. 33: 137-170.
38. Yonge, D. 2012. A Comparison of Aluminum and Iron-based Coagulants for Treatment of Surface Water in Sarasota County, Florida. (Tesis). University of Central Florida.

VIII. ANEXOS

ANEXO N° 1. CONTROL MENSUAL DE JULIO 2012 A MAYO 2013 PARA LA PRUEBA Y ENTRENAMIENTO DE LA RED OBTENIDOS CON LA PRUEBA DE JARRAS

CONTROL DIARIO DE PROCESOS Y PRODUCCIÓN												
MES:	JULIO											
FECHA	CONTROL DE PROCESOS											
	TURBIEDAD (NTU)			COLOR		pH		Conductividad (us)		TDS (ppm)		DOSIS
	Rio Shullcas	Agua Decantada	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Sulf. Al PPM
01-jul	1.64	1.73	0.67	11	0	7.70	7.40	286	291	143	145	8.21
02-jul	2.14	2.50	0.78	13	0	7.70	7.30	290	291	145	146	13.92
03-jul	1.93	2.02	0.77	12	0	7.80	7.35	284	286	142	143	12.29
04-jul	1.90	2.17	0.80	18	0	7.90	7.50	296	300	149	150	11.85
05-jul	2.63	2.48	0.72	9	0	7.70	7.40	299	300	149	150	9.15
06-jul	1.89	2.56	0.68	11	0	7.70	7.40	302	300	151	150	8.63
07-jul	2.63	2.48	0.72	9	0	7.70	7.40	299	300	149	150	9.15
08-jul	1.64	1.73	0.67	11	0	7.70	7.40	286	291	143	145	8.21
09-jul	1.90	2.17	0.80	18	0	7.90	7.50	296	300	149	150	11.85
10-jul	1.57	1.73	0.66	16	0	7.80	7.40	295	303	148	151	9.72
11-jul	1.50	1.58	0.37	9	0	7.70	7.50	310	313	155	157	12.97
12-jul	5.48	1.40	0.63	12	0	7.70	7.50	309	313	155	157	10.82
13-jul	1.38	1.44	0.41	13	0	7.80	7.40	306	316	158	158	8.49
14-jul	2.63	2.48	0.72	9	0	7.70	7.40	299	300	149	150	9.15
15-jul	2.63	2.48	0.72	9	0	7.70	7.40	299	300	149	150	9.15
16-jul	1.35	1.25	0.34	12	0	7.80	7.10	303	312	152	157	9.12
17-jul	1.30	1.37	0.28	12	0	7.70	7.30	299	306	149	154	7.47
18-jul	1.37	1.65	0.30	14	0	7.70	7.30	316	316	158	158	9.92
19-jul	2.63	2.48	0.72	9	0	7.70	7.40	299	300	149	150	9.15
20-jul	1.89	2.56	0.68	11	0	7.70	7.40	302	300	151	150	8.63
21-jul	1.48	1.86	0.41	21	0	7.90	7.30	286	299	143	150	9.67
22-jul	1.24	1.49	0.43	15	0	7.90	7.30	290	302	145	151	9.06
23-jul	1.90	2.17	0.80	18	0	7.90	7.50	296	300	149	150	11.85
24-jul	1.58	1.73	0.55	17	0	7.70	7.20	296	304	148	152	9.25
25-jul	1.53	1.68	0.37	13	0	8.00	7.35	297	308	132	138	10.44
26-jul	1.64	1.79	0.37	20	0	7.70	7.40	299	300	150	150	8.36
27-jul	1.59	1.78	0.34	14	0	7.70	7.40	297	300	149	150	8.77
28-jul	1.24	1.49	0.43	15	0	7.90	7.30	290	302	145	151	9.06
29-jul	1.64	1.73	0.67	11	0	7.70	7.40	286	291	143	145	8.21
30-jul	1.64	1.73	0.67	11	0	7.70	7.40	286	291	143	145	8.21
31-jul	1.53	1.76	0.31	19	0	7.60	7.40	289	290	145	145	8.17
PROM	1.91	1.92	0.57	13.22	0.00	7.76	7.38	296.25	300.75	147.82	149.88	9.64

CONTROL DIARIO DE PROCESOS Y PRODUCCIÓN

MES	AGOSTO											
FECHA	CONTROL DE PROCESOS											
	TURBIEDAD (NTU)			COLOR		pH		Conductividad (us)		TDS (ppm)		DOSIS
	Rio Shullcas	Agua Decantada	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Sulf. Al PPM
01-ago	1.47	1.73	0.28	10	0	7.70	7.30	291	298	146	149	9.35
02-ago	1.90	2.17	0.80	18	0	7.90	7.50	296	300	149	150	11.85
03-ago	1.24	1.49	0.43	15	0	7.90	7.30	290	302	145	151	9.06
04-ago	1.64	1.73	0.67	11	0	7.70	7.40	286	291	143	145	8.21
05-ago	1.48	1.47	0.37	18	0	7.80	7.40	299	310	150	155	8.46
06-ago	1.47	1.48	0.32	17	0	7.80	7.48	299	302	150	152	9.42
07-ago	1.66	1.70	0.38	21	0	7.60	7.20	303	305	152	153	9.01
08-ago	1.87	1.78	0.33	10	1	7.70	7.25	296	306	148	154	9.12
09-ago	1.24	1.49	0.43	15	0	7.90	7.30	290	302	145	151	9.06
10-ago	1.90	2.17	0.80	18	0	7.90	7.50	296	300	149	150	11.85
11-ago	1.24	1.49	0.43	15	0	7.90	7.30	290	302	145	151	9.06
12-ago	1.24	1.49	0.43	15	0	7.90	7.30	290	302	145	151	9.06
13-ago	1.68	1.69	0.39	12	0	7.85	7.40	264	276	132	139	9.37
14-ago	1.57	1.65	0.40	19	0	7.85	7.40	261	271	131	136	7.24
15-ago	1.79	1.77	0.40	20	0	7.90	7.30	266	278	133	139	6.87
16-ago	1.76	2.08	0.37	19	0	7.70	7.40	270	274	135	137	4.94
17-ago	1.64	1.73	0.67	11	0	7.70	7.40	286	291	143	145	8.21
18-ago	1.24	1.49	0.43	15	0	7.90	7.30	290	302	145	151	9.06
19-ago	1.24	1.49	0.43	15	0	7.90	7.30	290	302	145	151	9.06
20-ago	1.58	1.82	0.36	16	0	7.70	7.30	304	308	152	154	5.55
21-ago	1.84	1.65	0.40	18	0	7.70	7.40	302	306	151	153	8.00
22-ago	2.01	1.64	0.33	24	0	7.60	7.30	303	306	152	153	7.36
23-ago	5.80	0.66	67	5	0	7.40	245	255	124	128	10.32	10.31
24-ago	1.64	1.73	0.67	11	0	7.70	7.40	286	291	143	145	8.21
25-ago	5.10	5.07	0.48	39	0	7.80	7.40	279	283	140	142	7.69
26-ago	2.93	2.86	0.69	46	0	7.70	7.30	281	285	141	143	8.35
27-ago	2.75	2.71	0.42	36	2	7.90	7.60	284	284	142	142	9.69
28-ago	5.80	0.66	67	5	0	7.40	245	255	124	128	10.32	10.30
29-ago	3.64	3.17	0.50	17	0	7.80	7.30	281	285	141	143	7.99
30-ago	1.64	1.73	0.67	11	0	7.70	7.40	286	291	143	145	8.21
31-ago	2.37	2.41	0.40	21	2	7.50	7.35	281	286	141	146	11.04
PROM	2.14	1.88	4.76	17.43	0.13	7.75	22.69	285.40	283.40	142.92	138.53	8.74

CONTROL DIARIO DE PROCESOS Y PRODUCCIÓN

MES: SEPTIEMBRE

FECHA	CONTROL DE PROCESOS											
	TURBIEDAD (NTU)			COLOR		pH		Conductividad (us)		TDS (ppm)		DOSIS PROMEDIO (ppm)
	Rio Shullcas	Agua Decantada	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Sulf. Al PPM
01-sep	1.64	1.73	0.67	11	0	7.70	7.40	286	291	143	145	8.21
02-sep	1.24	1.49	0.43	15	0	7.90	7.30	290	302	145	151	9.06
03-sep	3.86	3.27	0.52	28	0	7.70	7.40	282	284	141	142	11.13
04-sep	5.89	4.83	0.61	61	1	7.70	7.30	264	268	132	134	11.44
05-sep	4.27	4.16	0.56	39	0	7.80	7.40	271	279	136	140	8.19
06-sep	4.87	4.16	0.48	54	0	7.75	7.50	272	278	136	139	14.70
07-sep	1.24	1.49	0.43	15	0	7.90	7.30	290	302	145	151	9.06
08-sep	2.37	2.41	0.40	21	2	7.50	7.35	281	286	141	146	11.04
09-sep	2.37	2.41	0.40	21	2	7.50	7.35	281	286	141	146	11.04
10-sep	6.09	5.80	0.66	67	5	7.70	7.40	245	255	124	128	10.32
11-sep	33.88	5.05	0.61	52	1	7.60	7.30	257	258	129	129	12.49
12-sep	6.14	4.85	0.62	62	0	7.40	7.20	253	257	127	129	10.89
13-sep	5.75	4.91	0.60	57	0	7.70	7.50	249	254	125	127	11.41
14-sep	2.37	2.41	0.40	21	2	7.50	7.35	281	286	141	146	11.04
15-sep	8.42	8.12	0.83	96	1	8.10	7.35	244	251	122	126	10.19
16-sep	7.25	6.17	0.80	68	1	7.80	7.50	245	249	123	125	10.22
17-sep	7.73	6.49	0.74	78	5	8.00	7.35	242	247	121	124	10.36
18-sep	9.31	7.75	0.77	93	1	7.80	7.50	235	237	118	119	14.22
19-sep	9.68	7.09	0.73	73	0	7.60	7.30	238	235	119	118	13.21
20-sep	9.68	7.09	0.73	73	0	7.60	7.30	238	235	119	118	13.21
21-sep	9.31	7.75	0.77	93	1	7.80	7.50	235	237	118	119	14.22
22-sep	47.00	16.83	1.09	115	0	7.70	7.10	229	231	115	116	21.76
23-sep	46.92	16.83	1.09	115	0	7.70	7.10	229	231	115	116	21.76
24-sep	9.04	6.69	0.58	102	0	7.50	7.10	237	244	119	122	19.33
25-sep	9.96	7.67	0.80	87	0	7.60	7.30	223	234	112	117	15.10
26-sep	9.57	7.48	0.84	65	0	7.60	7.40	236	237	118	119	14.91
27-sep	18.59	8.87	0.81	87	0	7.70	7.20	224	222	112	111	18.28
28-sep	46.92	16.83	1.09	115	0	7.70	7.10	229	231	115	116	21.76
29-sep	23.08	10.63	0.94	100	0	7.70	7.20	224	222	112	111	18.28
30-sep	18.59	8.87	0.81	87	0	7.70	7.20	224	222	112	111	18.28
PROM	12.43	6.67	0.69	65.63	0.67	7.70	7.32	251.07	254.93	125.78	127.97	13.50

CONTROL DIARIO DE PROCESOS Y PRODUCCIÓN

CONTROL DE PROCESOS												
FECHA	TURBIEDAD (NTU)			COLOR		pH		Conductividad (us)		TDS (ppm)		DOSIS PROMEDIO (ppm)
	Rio Shullcas	Agua Decantada	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Sulf. Al PPM
	01-oct	9.35	6.77	0.70	95	3	7.80	7.20	216	223	108	112
02-oct	8.81	6.51	0.70	83	0	7.50	7.40	213	223	107	112	18.09
03-oct	10.12	7.19	0.80	71	0	7.70	7.30	213	225	107	113	15.26
04-oct	9.23	6.75	0.73	90	3	7.80	7.20	216	223	108	112	19.60
05-oct	45.96	9.92	0.76	111	4	7.80	7.40	242	249	122	125	23.21
06-oct	11.92	8.64	0.92	51	0	7.90	7.50	271	277	136	139	20.97
07-oct	8.58	5.53	0.57	80	0	7.70	7.20	226	230	113	115	21.99
08-oct	14.41	7.05	0.63	101	2	7.80	7.10	228	236	114	118	23.62
09-oct	13.66	9.92	0.76	111	4	7.80	7.40	242	249	122	125	23.21
10-oct	12.52	8.64	0.92	51	0	7.90	7.50	271	277	136	139	20.97
11-oct	6.20	5.98	0.98	50	2	8.10	7.60	258	270	129	135	21.93
12-oct	4.70	4.86	0.80	42	0	7.80	7.50	257	261	129	131	16.14
13-oct	9.31	7.75	0.77	93	1	7.80	7.50	235	237	118	119	14.22
14-oct	18.59	8.87	0.81	87	0	7.70	7.20	224	222	112	111	18.28
15-oct	9.31	7.75	0.77	93	1	7.80	7.50	235	237	118	119	14.22
16-oct	4.74	4.69	0.98	30	0	8.15	7.40	267	273	134	137	15.70
17-oct	5.42	5.21	0.73	43	0	8.00	7.40	287	294	144	147	17.09
18-oct	5.15	5.10	0.90	46	0	8.00	7.40	268	275	134	138	15.52
19-oct	4.84	4.07	0.54	50	0	7.90	7.30	279	281	140	141	12.92
20-oct	18.59	8.87	0.81	87	0	7.70	7.20	224	222	112	111	18.28
21-oct	2.37	2.41	0.40	21	2	7.50	7.35	281	286	141	146	11.04
22-oct	5.63	4.86	0.55	37	0	8.00	7.45	287	294	144	148	17.82
23-oct	7.86	5.69	0.56	55	0	7.83	7.43	260	267	130	134	17.45
24-oct	10.17	7.46	0.53	72	0	7.85	7.40	241	247	121	124	17.20
25-oct	8.38	6.10	0.67	85	3	7.80	7.20	216	223	108	112	19.60
26-oct	18.59	8.87	0.81	87	0	7.70	7.20	224	222	112	111	18.28
27-oct	61.21	16.37	0.94	59	3	7.80	7.40	241	245	121	123	19.18
28-oct	11.54	6.70	0.68	63	0	7.80	7.20	237	239	119	120	16.81
29-oct	13.41	8.48	0.63	138	3	7.70	7.27	246	257	124	129	22.91
30-oct	8.34	5.35	0.43	62	0	7.55	7.20	295	302	148	151	19.54
31-oct	5.65	5.07	0.49	38	0	8.00	7.45	365	373	183	187	16.78
PROM	12.41	7.01	0.72	70.24	0.94	7.81	7.35	250.39	255.99	125.41	128.38	18.30

CONTROL DIARIO DE PROCESOS Y PRODUCCIÓN

CONTROL DE PROCESOS												
FECHA	TURBIEDAD (NTU)			COLOR		pH		Conductividad (us)		TDS (ppm)		DOSIS PROMEDIO (ppm)
	Rio Shullcas	Agua Decantada	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Sulf. Al PPM
	01-nov	13.23	7.59	0.53	120	0	7.70	7.20	224	222	112	111
02-nov	76.60	15.87	0.83	160	0	7.70	7.20	224	222	112	111	18.28
03-nov	9.31	7.75	0.77	93	1	7.80	7.50	235	237	118	119	14.22
04-nov	7.38	8.16	0.88	120	0	7.70	7.20	224	222	112	111	18.28
05-nov	68.34	9.89	1.13	123	0	7.73	7.23	280	295	157	148	19.00
06-nov	21.83	14.85	2.15	134	7	7.40	7.00	218	199	109	100	19.89
07-nov	7.80	8.83	1.41	78	0	7.60	7.20	266	273	183	186	19.95
08-nov	61.21	16.37	0.94	59	3	7.80	7.40	241	245	121	123	19.18
09-nov	11.54	6.70	0.68	63	0	7.80	7.20	237	239	119	120	16.81
10-nov	13.41	8.48	0.63	138	3	7.70	7.27	246	257	124	129	22.91
11-nov	8.34	5.35	0.43	62	0	7.55	7.20	295	302	148	151	19.54
12-nov	5.65	5.07	0.49	38	0	8.00	7.45	365	373	183	187	16.78
13-nov	5.63	4.86	0.55	37	0	8.00	7.45	287	294	144	148	17.82
14-nov	7.86	5.69	0.56	55	0	7.83	7.43	260	267	130	134	17.45
15-nov	10.17	7.46	0.53	72	0	7.85	7.40	241	247	121	124	17.20
16-nov	13.41	8.48	0.63	138	3	7.70	7.27	246	257	124	129	22.91
17-nov	5.56	5.10	1.11	40	1	7.85	7.70	316	322	158	161	11.04
18-nov	61.21	16.37	0.94	59	3	7.80	7.40	241	245	121	123	19.18
19-nov	11.54	6.70	0.68	63	0	7.80	7.20	237	239	119	120	16.81
20-nov	13.41	8.48	0.63	138	3	7.70	7.27	246	257	124	129	22.91
21-nov	5.56	5.10	1.11	40	1	7.85	7.70	316	322	158	161	11.04
22-nov	7.65	6.40	1.20	37	1	7.76	7.62	330	336	165	168	9.63
23-nov	10.04	9.14	1.34	65	6	7.93	7.78	296	298	148	149	8.28
24-nov	2.37	2.41	0.40	21	2	7.50	7.35	281	286	141	146	11.04
25-nov	12.82	10.27	1.41	49	9	8.15	7.69	317	313	159	157	10.41
26-nov	2.37	2.41	0.40	21	2	7.50	7.35	281	286	141	146	11.04
27-nov	21.83	14.85	2.15	134	7	7.40	7.00	218	199	109	100	19.89
28-nov	7.80	8.83	1.41	78	0	7.60	7.20	266	273	183	186	19.95
29-nov	61.21	16.37	0.94	59	3	7.80	7.40	241	245	121	123	19.18
30-nov	11.54	6.70	0.68	63	0	7.80	7.20	237	239	119	120	16.81
PROM	19.22	8.68	0.92	78.44	1.78	7.74	7.35		266.98	135.96	137.23	16.86

CONTROL DIARIO DE PROCESOS Y PRODUCCIÓN

CONTROL DE PROCESOS												
FECHA	TURBIEDAD (NTU)			COLOR		pH		Conductividad (us)		TDS (ppm)		DOSIS PROMEDIO (ppm)
	Rio Shullcas	Agua Decantada	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Sulf. Al PPM
	01-dic	6.83	7.12	1.01	38	3	7.77	7.86	312	318	156	159
02-dic	6.48	8.15	1.24	41	3	7.90	7.81	314	322	157	161	8.02
03-dic	1.90	2.17	0.80	18	0	7.90	7.50	296	300	149	150	11.85
04-dic	1.90	2.17	0.80	18	0	7.90	7.50	296	300	149	150	11.85
05-dic	5.56	5.10	1.11	40	1	7.85	7.70	316	322	158	161	11.04
06-dic	7.65	6.40	1.20	37	1	7.76	7.62	330	336	165	168	9.63
07-dic	10.04	9.14	1.34	65	6	7.93	7.78	296	298	148	149	8.28
08-dic	2.37	2.41	0.40	21	2	7.50	7.35	281	286	141	146	11.04
09-dic	12.82	10.27	1.41	49	9	8.15	7.69	317	313	159	157	10.41
10-dic	1.90	2.17	0.80	18	0	7.90	7.50	296	300	149	150	11.85
11-dic	38.65	15.49	33.68	183	8	7.83	7.40	159	168	79	84	31.79
12-dic	126.40	16.02	3.59	109	5	7.80	7.40	163	170	81	85	30.90
13-dic	167.78	32.61	3.08	120	4	7.90	7.44	170	196		98	32.37
14-dic	31.91	24.33	3.52	141	1	8.39	7.71	184	187	92	94	27.15
15-dic	83.08	15.49	33.68	183	0	7.83	7.40	159	168	79	84	31.79
16-dic	78.37	23.52	3.83	123	3	8.09	7.38	137	137	69	70	32.06
17-dic	43.64	20.46	3.77	201	6	7.75	7.42	125	132	62	66	30.93
18-dic	38.65	15.49	33.68	183	2	7.83	7.40	159	168	79	84	31.79
19-dic	126.40	15.49	33.68	183	2	7.83	7.40	159	168	79	84	31.79
20-dic	235.53	17.06	3.46	135	2	7.80	7.40	144	156	75	78	29.72
21-dic	30.99	18.39	3.57	101	2	7.90	7.30	160	168	80	84	27.76
22-dic	117.85	24.33	3.52	141	1	8.39	7.71	184	187	92	94	27.15
23-dic	73.12	24.33	3.52	141	1	8.39	7.71	184	187	92	94	27.15
24-dic	13.45	15.49	33.68	183	0	7.83	7.40	159	168	79	84	31.79
25-dic	54.62	23.52	3.83	123	17	8.09	7.38	137	137	69	70	32.06
26-dic	46.05	15.49	33.68	183	2	7.83	7.40	159	168	79	84	31.79
27-dic	18.59	8.87	0.81	87	0	7.70	7.20	224	222	112	111	18.28
28-dic	51.06	9.49	2.08	65	7	7.70	7.10	198	201	99	101	14.29
29-dic	29.23	9.39	1.92	67	2	8.20	7.10	198	205	99	104	20.62
30-dic	10.79	9.46	2.24	68.00	2	8.20	7.20	186	191	93	68	21.28
31-dic	21.27	24.33	3.52	141	1	8.39	7.71	184	187	92	94	27.15
PROM	48.22	14.00	8.34	103.35	2.98	7.94	7.48		218.20	106.97	108.48	22.34

CONTROL DIARIO DE PROCESOS Y PRODUCCIÓN

MES:	ENERO											
FECHA	CONTROL DE PROCESOS											
	TURBIEDAD (NTU)			COLOR		pH		Conductividad (us)		TDS (ppm)		DOSIS PROMEDIO (ppm)
	Rio Shullcas	Agua Decantada	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Sulf. Al PPM
01-ene	86.33	15.96	2.95	89	8	7.70	6.90	170	170	86	85	22.52
02-ene	16.53	17.11	3.33	81	7	7.80	6.90	164	156	82	78	25.68
03-ene	9.97	24.33	3.52	141	1	8.39	7.71	184	187	92	94	27.15
04-ene	9.78	15.49	33.68	183	0	7.83	7.40	159	168	79	84	31.79
05-ene	15.51	23.52	3.83	123	17	8.09	7.38	137	137	69	70	32.06
06-ene	43.66	24.33	3.52	141	1	8.39	7.71	184	187	92	94	27.15
07-ene	28.83	38.24	0.85	40	2	8.10	7.70	235	241	117	120	15.35
08-ene	14.95	3.13	0.80	39	10	8.00	7.55	236	244	118	122	17.72
09-ene	225.09	18.01	2.34	103	19	7.80	6.90	174	175	87	88	28.46
10-ene	19.51	16.66	3.00	128	12	7.60	6.80	163	167	82	84	27.74
11-ene	11.34	11.39	2.54	100	10	7.60	6.80	186	191	93	68	21.28
12-ene	9.41	9.49	2.08	65	7	7.70	7.10	198	201	99	101	14.29
13-ene	17.31	9.39	1.92	67	2	8.20	7.10	198	205	99	104	20.62
14-ene	8.65	38.24	0.85	40	2	8.10	7.70	235	241	117	120	15.35
15-ene	5.24	3.13	0.80	39	1	8.00	7.55	236	244	118	122	17.72
16-ene	8.11	5.87	1.22	86	1	8.00	7.40	227	231	114	116	17.62
17-ene	4.26	3.13	0.80	39	1	8.00	7.55	236	244	118	122	17.72
18-ene	3.94	4.72	1.12	30	0	8.20	7.40	231	237	116	119	14.79
19-ene	4.45	4.40	1.19	38	4	8.20	7.30	234	244	117	122	18.68
20-ene	4.63	5.67	1.17	53	8	8.10	7.30	222	230	111	115	16.98
21-ene	18.59	8.87	0.81	87	0	7.70	7.20	224	222	112	111	18.28
22-ene	15.54	5.47	1.21	37	1	8.10	7.40	225	230	113	115	18.63
23-ene	16.41	9.94	1.39	84	0	8.00	7.10	200	204	100	102	22.41
24-ene	6.61	6.68	1.53	52	0	8.10	7.60	208	206	104	103	19.70
25-ene	4.38	5.47	1.21	37	1	8.10	7.40	225	230	113	115	18.63
26-ene	17.06	10.65	1.34	64	8	8.20	7.50	201	201	101	101	21.27
27-ene	82.72	17.74	1.79	616	9	8.20	7.40	54	181	27	91	31.02
28-ene	13.87	7.11	1.57	167	5	8.50	7.50	205	209	103	105	18.58
29-ene	17.06	10.65	1.34	64	8	8.20	7.50	201	201	101	101	21.27
30-ene	82.72	17.74	1.79	616	9	8.20	7.40	54	181	27	91	31.02
31-ene	17.20	11.70	2.11	179	2	8.00	7.10	142	143	71	71	25.04
PROM	27.09	13.04	2.83	117.03	5.03	8.04	7.33	191.85	203.47	96.04	101.03	21.82

CONTROL DIARIO DE PROCESOS Y PRODUCCIÓN

MES:	FEBRERO											
FECHA	CONTROL DE PROCESOS											
	TURBIEDAD (NTU)			COLOR		pH		Conductividad (us)		TDS (ppm)		DOSIS PROME DIO (ppm)
	Rio Shullcas	Agua Decantada	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Sulf. Al PPM
01-feb	8.59	9.09	1.62	94	6	7.60	7.30	183	188	93	94	19.47
02-feb	10.35	8.80	2.09	132	12	7.90	7.30	178	178	89	89	20.77
03-feb	41.97	8.70	1.93	66	10	8.10	7.30	180	185	90	92	27.20
04-feb	38.14	20.67	2.57	144	12	7.90	7.50	136	132	65	66	20.45
05-feb	22.23	24.33	3.52	141	1	8.39	7.71	184	187	92	94	27.15
06-feb	14.10	11.27	2.64	124	15	8.00	7.40	150	149	75	75	28.38
07-feb	38.14	20.67	2.57	144	12	7.90	7.50	136	132	65	66	20.45
08-feb	57.87	19.57	2.47	253	12	8.30	7.30	111	138	56	62	23.88
09-feb	26.54	15.71	2.57	203	5	7.33	6.85	135	145	68	72	22.69
10-feb	25.14	13.58	3.02	204	13	6.65	6.60	154	158	77	79	22.32
11-feb	19.89	3.13	0.80	39	10	8.00	7.55	236	244	118	122	17.72
12-feb	18.68	14.21	2.84	178	15	8.20	7.40	146	150	73	75	24.68
13-feb	42.16	20.99	3.05	230	13	8.80	7.50	152	162	76	81	20.86
14-feb	20.76	12.09	3.11	157	14	8.00	7.20	164	167	82	83	19.12
15-feb	8.27	7.91	1.68	95	10	7.05	6.75	184	189	92	94	19.71
16-feb	7.09	6.56	1.93	91	1	7.35	7.20	196	192	99	97	19.16
17-feb	7.62	7.14	1.77	71	8	6.80	6.70	191	196	96	98	21.49
18-feb	27.48	3.13	0.80	39	7	8.00	7.55	236	244	118	122	17.72
19-feb	16.91	3.13	0.80	39	6	8.00	7.55	236	244	118	122	17.72
20-feb	12.94	24.33	3.52	141	1	8.39	7.71	184	187	92	94	27.15
21-feb	21.34	9.24	2.49	110	5	7.40	6.70	182	177	88	86	23.83
22-feb	22.65	11.42	5.79	116	10	7.25	6.65	186	145	93	95	23.88
23-feb	39.82	14.24	2.82	146	4	7.20	6.60	164	166	82	83	22.90
24-feb	85.42	14.21	2.84	178	15	8.20	7.40	146	150	73	75	24.68
25-feb	23.68	11.11	2.17	154	12	7.35	6.60	143	144	72	72	24.27
26-feb	38.01	11.37	2.51	171	11	7.40	6.70	143	148	71	74	19.73
27-feb	19.25	14.21	2.84	178	15	8.20	7.40	146	150	73	75	24.68
28-feb	111.25	9.24	2.49	110	10	7.40	6.70	182	177	88	86	23.83
PROM	29.51	12.50	2.47	133.82	9.45	7.75	7.17	170.18	172.34	84.75	86.59	22.35

CONTROL DIARIO DE PROCESOS Y PRODUCCIÓN

CONTROL DIARIO DE PROCESOS Y PRODUCCIÓN												
MES:	MARZO											
FECHA	CONTROL DE PROCESOS											
	TURBIEDAD (NTU)			COLOR		pH		Conductividad (us)		TDS (ppm)		DOSIS PROMEDIO (ppm)
	Rio Shullcas	Agua Decantada	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Sulf. Al PPM
01-mar	24.38	18.17	2.51	178	9	7.50	6.70	143	140	71	70	23.26
02-mar	33.76	16.02	3.18	339	10	7.50	6.65	136	149	68	74	23.16
03-mar	27.33	14.21	2.84	178	15	8.20	7.40	146	150	73	75	24.68
04-mar	54.47	14.21	2.84	178	15	8.20	7.40	146	150	73	75	24.68
05-mar	20.59	14.91	2.75	226	10	7.35	6.70	127	134	63	67	25.34
06-mar	29.20	19.64	3.06	215	9	7.40	6.65	110	124	55	61	27.03
07-mar	20.18	14.55	2.64	298	10	7.55	6.70	111	131	56	65	25.86
08-mar	23.91	14.24	2.82	146	12	7.20	6.60	164	166	82	83	22.90
09-mar	58.13	14.21	2.84	178	15	8.20	7.40	146	150	73	75	24.68
10-mar	35.35	12.19	3.35	208	12	7.45	6.70	166	159	70	75	21.64
11-mar	14.60	11.64	3.26	161	9	7.50	6.70	152	158	77	79	18.55
12-mar	28.81	11.98	3.03	130	10	7.50	7.05	162	160	82	80	16.46
13-mar	28.05	14.21	2.84	178	15	8.20	7.40	146	150	73	75	24.68
14-mar	11.15	14.21	2.84	178	15	8.20	7.40	146	150	73	75	24.68
15-mar	20.91	13.35	2.44	119	14	7.50	7.00	150	165	74	82	17.43
16-mar	23.71	14.24	2.82	146	12	7.20	6.60	164	166	82	83	22.90
17-mar	9.62	9.54	2.61	74	9	7.45	6.85	160	163	80	81	18.29
18-mar	18.59	8.87	0.81	87	12	7.70	7.20	224	222	112	111	18.28
19-mar	8.64	6.71	1.93	165	3	8.50	7.70	150	190	84	95	18.24
20-mar	28.99	14.00	2.22	153	4	8.40	7.90	194	187	97	94	19.26
21-mar	8.05	8.35	1.70	69	1	8.10	7.90	195	224	98	112	17.99
22-mar	5.28	5.64	1.44	64	6	6.10	6.90	183	188	93	94	17.00
23-mar	5.30	5.62	1.49	54	5	7.30	6.65	193	194	97	97	15.61
24-mar	4.66	5.54	1.40	43	7	7.00	7.70	191	198	96	96	16.50
25-mar	4.22	4.82	1.28	24	6	8.30	7.80	198	202	99	101	15.72
26-mar	4.88	5.46	1.20	28	2	7.60	7.30	194	198	97	99	16.73
27-mar	4.23	4.82	1.69	41	3	7.00	7.70	189	190	95	95	15.86
28-mar	4.81	5.42	1.60	30	0	8.30	7.80	194	201	97	101	16.51
29-mar	3.49	4.20	1.46	39	2	7.80	7.30	191	196	96	98	16.67
30-mar	21.57	5.92	1.81	44	1	7.70	7.30	192	200	92	100	17.15
31-mar	3.62	14.21	2.84	178	15	8.20	7.40	146	150	73	75	24.68
PROM	19.05	11.00	2.31	133.74	8.63	7.68	7.18		171.14	82.31	85.30	20.40

CONTROL DIARIO DE PROCESOS Y PRODUCCIÓN

CONTROL DE PROCESOS												
FECHA	TURBIEDAD (NTU)			COLOR		pH		Conductividad (us)		TDS (ppm)		DOSIS PROMEDIO (ppm)
	Rio Shullcas	Agua Decantada	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Sulf. Al PPM
	01-abr	2.86	3.65	0.63	41	0	7.90	7.30	192	190	96	95
02-abr	2.74	3.27	0.70	23	1	7.90	7.35	195	201	98	101	13.34
03-abr	27.91	24.33	3.52	141	1	8.39	7.71	184	187	92	94	27.15
04-abr	15.22	15.49	33.68	183	0	7.83	7.40	159	168	79	84	31.79
05-abr	7.32	23.52	3.83	123	17	8.09	7.38	137	137	69	70	32.06
06-abr	9.33	14.21	2.84	178	15	8.20	7.40	146	150	73	75	24.68
07-abr	54.00	8.78	1.87	23	0	8.20	7.71	192	195	96	97	22.48
08-abr	3.59	4.95	0.90	69	0	8.90	7.40	170	175	85	87	13.34
09-abr	2.86	3.65	0.63	41	0	7.90	7.30	192	190	96	95	13.67
10-abr	6.19	4.29	0.80	69	0	7.80	7.40	190	198	95	99	14.87
11-abr	10.01	5.57	1.00	37	1	7.80	7.40	198	193	99	92	17.64
12-abr	46.90	11.80	1.07	145	15	7.70	7.20	145	149	66	75	23.88
13-abr	137.43	17.17	1.57	310	15	7.90	7.30	97	97	49	49	35.49
14-abr	25.61	14.24	2.82	146	14	7.20	6.60	164	166	82	83	22.90
15-abr	26.10	14.21	2.84	178	15	8.20	7.40	146	150	73	75	24.68
16-abr	13.62	10.76	1.98	180	15	8.20	7.45	150	162	75	86	17.85
17-abr	36.25	15.88	2.51	390	12	8.20	7.20	140	174	70	87	21.15
18-abr	13.56	11.77	1.97	138	15	8.00	7.40	141	145	70	72	19.69
19-abr	9.04	14.10	2.84	178	15	8.20	7.40	146	150	73	75	24.50
20-abr	6.10	14.21	2.84	178	15	8.20	7.30	146	150	73	75	24.68
21-abr	4.54	5.74	1.71	54	12	7.80	7.40	189	194	100	97	19.37
22-abr	10.85	5.64	1.56	58	11	7.80	7.40	193	195	97	97	15.04
23-abr	8.74	8.07	1.88	78	12	7.70	7.20	172	178	86	89	20.52
24-abr	4.64	6.32	1.83	70	10	7.90	7.30	180	184	90	92	18.44
25-abr	9.38	7.18	1.51	56	12	7.20	6.60	179	187	90	94	19.99
26-abr	5.46	6.73	1.85	72	8	8.20	7.40	180	175	90	88	18.64
27-abr	4.31	5.50	1.75	43	2	8.20	7.45	185	194	93	97	17.78
28-abr	5.43	38.24	0.85	40	3	8.10	7.70	235	241	117	120	15.35
29-abr	4.05	3.13	0.80	39	3	8.00	7.55	236	244	118	122	17.72
30-abr	3.58	4.67	1.30	25	0	7.70	7.50	198	209	99	105	19.93
PROM	17.25	10.90	2.86	110.20	7.97	7.98	7.35		177.60	86.31	88.87	20.74

CONTROL DIARIO DE PROCESOS Y PRODUCCIÓN

CONTROL DE PROCESOS												
FECHA	TURBIEDAD (NTU)			COLOR		pH		Conductividad (us)		TDS (ppm)		DOSIS
	Rio Shullcas	Agua Decantada	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Ingreso	Salida	Sulf. Al PPM
	01-may	3.29	4.40	1.42	19	5	8.00	7.70	196	205	99	100
02-may	4.05	5.88	1.21	13	0	8.00	7.60	199	188	99	95	17.75
03-may	4.48	38.24	0.85	40	0	8.10	7.70	235	241	117	120	15.35
04-may	3.02	3.13	0.80	39	2	8.00	7.55	236	244	118	122	17.72
05-may	2.73	3.53	1.27	14	0	7.70	7.50	207	221	104	110	17.38
06-may	2.57	3.73	1.30	17	3	8.10	7.55	216	225	108	115	18.93
07-may	2.51	2.85	1.10	18	1	7.80	7.40	226	226	113	113	15.90
08-may	2.32	3.76	1.17	17	0	7.60	7.50	223	226	112	115	14.31
09-may	2.19	2.64	0.90	18	0	8.05	7.60	226	230	112	115	10.32
10-may	2.26	2.48	0.79	9	0	8.00	7.50	230	235	115	118	11.01
11-may	2.03	2.35	0.67	13	0	8.05	7.85	230	233	114	117	9.54
12-may	2.17	2.40	0.75	9	0	8.30	7.70	233	238	117	118	9.97
13-may	1.93	2.43	0.63	9	0	8.30	7.70	233	236	117	118	10.37
14-may	1.70	2.47	0.82	12	0	8.30	7.75	236	244	119	122	12.92
15-may	1.87	38.24	0.85	40	1	8.10	7.70	235	241	117	120	15.35
16-may	1.90	3.13	0.80	39	0	8.00	7.55	236	244	118	122	17.72
17-may	1.83	2.65	0.86	20	0	8.40	7.53	238	244	119	122	18.29
18-may	11.54	14.21	2.84	178	15	8.20	7.40	146	150	73	75	24.68
19-may	4.39	4.87	1.06	14	0	8.20	7.60	238	239	118	119	18.35
20-may	3.05	4.12	0.79	19	0	7.80	7.70	232	232	116	116	17.11
21-may	4.23	3.39	0.79	18	0	8.15	7.65	239	237	119	119	15.44
22-may	3.37	3.30	0.88	19	0	7.90	7.40	245	249	121	124	16.14
23-may	3.00	14.21	2.84	178	15	8.20	7.40	146	150	73	75	24.68
24-may	2.91	3.35	0.64	18	0	7.90	7.60	244	248	122	124	13.12
25-may	28.58	7.54	1.02	101	0	8.10	7.55	246	252	123	127	18.49
26-may	21.74	8.42	1.31	25	0	8.10	7.60	253	255	128	127	15.53
27-may	3.40	4.30	1.18	10	0	8.40	7.60	261	262	131	130	15.73
28-may	3.43	4.38	0.90	31	1	7.90	7.55	259	265	130	133	14.77
29-may	7.69	5.25	1.31	55	0	7.90	7.55	258	265	129	133	15.80
30-may	3.72	38.24	0.85	40	0	8.10	7.70	235	241	117	120	15.35
31-may	3.22	3.13	0.80	39	2	8.00	7.55	236	244	118	122	17.72
PROM	4.75	7.84	1.08	35.11	1.40	8.05	7.59	228.15	232.51	114.09	116.27	15.98

**ANEXO N° 2. DATOS DE SALIDA DE LA DOSIS (ppm) EN EL
ENTRENAMIENTO Y PRUEBA DE RED NEURONAL DE TRES CAPAS CON
UNA OCULTA DE CINCO NEURONAS**

<u>DATOS DE SALIDA DE LA DOSIS (ppm) EN EL ENTRENAMIENTO Y PRUEBA</u>							
<u>RED DE UNA TRES CAPAS (UNA OCULTA DE 5 NEURONAS)</u>							
Datos de entrenamiento				Datos de prueba			
N° Fila	Real	De predicción	Residual	N° Fila	Real	De predicción	Residual
6	8.63	10.14	-1.51	1	8.21	10.57	-2.36
7	9.15	10.13	-0.98	2	13.92	10.73	3.19
10	9.72	10.42	-0.70	3	12.29	10.88	1.41
11	12.97	9.13	3.84	4	11.85	10.99	0.86
12	10.82	9.58	1.24	5	9.15	10.13	-0.98
13	8.49	10.61	-2.12	8	8.21	10.57	-2.36
18	9.92	8.70	1.22	9	11.85	10.99	0.86
21	9.67	10.54	-0.87	14	9.15	10.13	-0.98
26	8.36	9.98	-1.62	15	9.15	10.13	-0.98
35	8.21	10.57	-2.36	16	9.12	9.12	0.00
36	8.46	9.86	-1.40	17	7.47	9.20	-1.73
41	11.85	10.99	0.86	19	9.15	10.13	-0.98
42	9.06	10.10	-1.04	20	8.63	10.14	-1.51
43	9.06	10.10	-1.04	22	9.06	10.10	-1.04
44	9.37	11.36	-1.99	23	11.85	10.99	0.86
46	6.87	11.39	-4.52	24	9.25	9.89	-0.64
47	4.94	11.29	-6.35	25	10.44	5.59	4.85
48	8.21	10.57	-2.36	27	8.77	9.91	-1.14
49	9.06	10.10	-1.04	28	9.06	10.10	-1.04
50	9.06	10.10	-1.04	29	8.21	10.57	-2.36
51	5.55	9.43	-3.88	30	8.21	10.57	-2.36
55	8.21	10.57	-2.36	31	8.17	10.31	-2.14
56	7.69	12.73	-5.04	32	9.35	9.92	-0.57
61	8.21	10.57	-2.36	33	11.85	10.99	0.86
64	9.06	10.10	-1.04	34	9.06	10.10	-1.04
65	11.13	11.54	-0.41	37	9.42	9.88	-0.46
66	11.44	13.52	-2.08	38	9.01	9.55	-0.54
69	9.06	10.10	-1.04	39	9.12	9.42	-0.30
71	11.04	10.66	0.38	40	9.06	10.10	-1.04
72	10.32	14.83	-4.51	45	7.24	11.76	-4.52
73	12.49	13.82	-1.33	52	8.00	9.65	-1.65
80	14.22	17.22	-3.00	53	7.36	9.64	-2.28
84	21.76	21.47	0.29	54	10.31	11.33	-1.02
85	21.76	21.47	0.29	57	8.35	12.03	-3.68

87	15.10	17.52	-2.42
90	21.76	21.47	0.29
94	18.09	17.40	0.69
98	20.97	15.34	5.63
99	21.99	15.97	6.02
102	20.97	15.34	5.63
105	14.22	17.22	-3.00
106	18.28	17.74	0.54
107	14.22	17.22	-3.00
115	17.45	14.20	3.25
121	22.91	17.35	5.56
122	19.54	12.22	7.32
127	18.28	18.27	0.01
128	19.00	21.07	-2.07
129	19.89	21.34	-1.45
131	19.18	19.24	-0.06
132	16.81	15.83	0.98
135	16.78	8.86	7.92
136	17.82	12.43	5.39
138	17.20	16.18	1.02
142	16.81	15.83	0.98
143	22.91	17.35	5.56
148	10.41	13.21	-2.80
152	19.18	19.24	-0.06
156	11.85	10.99	0.86
159	9.63	11.53	-1.90
160	8.28	14.37	-6.09
166	32.37	29.84	2.53
168	31.79	28.62	3.17
169	32.06	31.41	0.65
171	31.79	28.31	3.48
173	29.72	29.20	0.52
174	27.76	27.51	0.25
175	27.15	30.24	-3.09
177	31.79	28.62	3.17
179	31.79	28.31	3.48
180	18.28	17.74	0.54
181	14.29	18.91	-4.62
182	20.62	19.72	0.90
184	27.15	30.24	-3.09
189	32.06	29.25	2.81
196	14.29	18.91	-4.62
197	20.62	19.72	0.90
202	14.79	15.49	-0.70

58	9.69	11.28	-1.59
59	10.30	11.70	-1.40
60	7.99	11.36	-3.37
62	11.04	10.66	0.38
63	8.21	10.57	-2.36
67	8.19	12.84	-4.65
68	14.70	12.99	1.71
70	11.04	10.66	0.38
74	10.89	14.13	-3.24
75	11.41	14.64	-3.23
76	11.04	10.66	0.38
77	10.19	16.92	-6.73
78	10.22	15.65	-5.43
79	10.36	15.23	-4.87
81	13.21	16.09	-2.88
82	13.21	16.09	-2.88
83	14.22	17.22	-3.00
86	19.33	16.34	2.99
88	14.91	16.38	-1.47
89	18.28	17.74	0.54
91	18.28	18.83	-0.55
92	18.28	17.74	0.54
93	19.60	16.94	2.66
95	15.26	17.50	-2.24
96	19.60	16.87	2.73
97	23.21	17.65	5.56
100	23.62	16.61	7.01
101	23.21	17.65	5.56
103	21.93	14.73	7.20
104	16.14	14.19	1.95
108	15.70	13.63	2.07
109	17.09	12.85	4.24
110	15.52	13.81	1.71
111	12.92	12.59	0.33
112	18.28	17.74	0.54
113	11.04	10.66	0.38
114	17.82	12.43	5.39
116	17.20	16.18	1.02
117	19.60	16.45	3.15
118	18.28	17.74	0.54
119	19.18	19.24	-0.06
120	16.81	15.83	0.98
123	16.78	8.86	7.92
124	18.28	17.67	0.61

204	16.98	15.31	1.67
208	19.70	18.25	1.45
209	18.63	16.10	2.53
216	19.47	20.29	-0.82
220	27.15	29.11	-1.96
221	28.38	22.89	5.49
224	22.69	27.75	-5.06
232	21.49	17.32	4.17
234	17.72	13.52	4.20
240	24.27	22.80	1.47
242	24.68	25.67	-0.99
244	23.26	26.73	-3.47
247	24.68	25.67	-0.99
248	25.34	27.33	-1.99
249	27.03	30.27	-3.24
250	25.86	29.74	-3.88
251	22.90	23.36	-0.46
252	24.68	25.67	-0.99
253	21.64	21.26	0.38
261	18.28	15.89	2.39
264	17.99	20.35	-2.36
271	16.51	18.32	-1.81
273	17.15	17.19	-0.04
275	13.67	16.24	-2.57
276	13.34	15.67	-2.33
277	27.15	30.19	-3.04
279	32.06	29.25	2.81
280	24.68	25.67	-0.99
281	22.48	19.69	2.79
285	17.64	16.90	0.74
287	35.49	30.45	5.04
288	22.90	23.05	-0.15
289	24.68	25.67	-0.99
290	17.85	23.34	-5.49
294	24.68	25.57	-0.89
295	19.37	18.25	1.12
296	15.04	16.82	-1.78
297	20.52	18.97	1.55
299	19.99	16.74	3.25
301	17.78	18.63	-0.85
302	15.35	14.44	0.91
305	19.76	16.66	3.10
309	17.38	15.87	1.51
310	18.93	15.25	3.68

125	18.28	22.00	-3.72
126	14.22	17.22	-3.00
130	19.95	29.07	-9.12
133	22.91	17.35	5.56
134	19.54	12.22	7.32
137	17.45	14.20	3.25
139	22.91	17.35	5.56
140	11.04	11.78	-0.74
141	19.18	19.24	-0.06
144	11.04	11.78	-0.74
145	9.63	11.53	-1.90
146	8.28	14.37	-6.09
147	11.04	10.66	0.38
149	11.04	10.66	0.38
150	19.89	21.34	-1.45
151	19.95	29.07	-9.12
153	16.81	15.83	0.98
154	9.12	12.40	-3.28
155	8.02	13.02	-5.00
157	11.85	10.99	0.86
158	11.04	11.78	-0.74
161	11.04	10.66	0.38
162	10.41	13.21	-2.80
163	11.85	10.99	0.86
164	31.79	27.38	4.41
165	30.90	26.14	4.76
167	27.15	30.24	-3.09
170	30.93	31.62	-0.69
172	31.79	28.31	3.48
176	27.15	30.24	-3.09
178	32.06	29.25	2.81
183	21.28	20.77	0.51
185	22.52	24.02	-1.50
186	25.68	24.91	0.77
187	27.15	24.54	2.61
188	31.79	28.62	3.17
190	27.15	30.24	-3.09
191	15.35	20.08	-4.73
192	17.72	12.90	4.82
193	28.46	22.34	6.12
194	27.74	24.62	3.12
195	21.28	20.61	0.67
198	15.35	16.37	-1.02
199	17.72	14.29	3.43

313	10.32	14.19	-3.87
316	9.97	14.01	-4.04
317	10.37	13.89	-3.52
321	18.29	13.96	4.33
323	18.35	14.62	3.73
326	16.14	13.16	2.98
327	24.68	25.67	-0.99
328	13.12	13.52	-0.40
329	18.49	17.27	1.22
331	15.73	13.85	1.88
333	15.80	15.08	0.72
335	17.72	14.14	3.58

200	17.62	17.20	0.42
201	17.72	14.29	3.43
203	18.68	14.63	4.05
205	18.28	17.74	0.54
206	18.63	16.10	2.53
207	22.41	19.85	2.56
210	21.27	18.97	2.30
211	31.02	31.98	-0.96
212	18.58	20.52	-1.94
213	21.27	18.97	2.30
214	31.02	31.98	-0.96
215	25.04	25.75	-0.71
217	20.77	20.55	0.22
218	27.20	19.21	7.99
219	20.45	27.21	-6.76
222	20.45	27.21	-6.76
223	23.88	31.09	-7.21
225	22.32	24.98	-2.66
226	17.72	12.90	4.82
227	24.68	25.67	-0.99
228	20.86	29.78	-8.92
229	19.12	23.73	-4.61
230	19.71	18.08	1.63
231	19.16	19.43	-0.27
233	17.72	13.37	4.35
235	27.15	30.24	-3.09
236	23.83	19.98	3.85
237	23.88	20.95	2.93
238	22.90	24.59	-1.69
239	24.68	25.67	-0.99
241	19.73	23.66	-3.93
243	23.83	19.20	4.63
245	23.16	28.23	-5.07
246	24.68	25.67	-0.99
254	18.55	24.68	-6.13
255	16.46	23.61	-7.15
256	24.68	25.67	-0.99
257	24.68	25.67	-0.99
258	17.43	22.64	-5.21
259	22.90	23.36	-0.46
260	18.29	20.78	-2.49
262	18.24	25.99	-7.75
263	19.26	24.43	-5.17
265	17.00	17.51	-0.51

266	15.61	16.59	-0.98
267	16.50	16.97	-0.47
268	15.72	16.50	-0.78
269	16.73	16.74	-0.01
270	15.86	17.68	-1.82
272	16.67	17.14	-0.47
274	24.68	25.67	-0.99
278	31.79	28.62	3.17
282	13.34	18.86	-5.52
283	13.67	16.24	-2.57
284	14.87	17.44	-2.57
286	23.88	20.08	3.80
291	21.15	31.11	-9.96
292	19.69	22.95	-3.26
293	24.50	25.63	-1.13
298	18.44	18.20	0.24
300	18.64	18.95	-0.31
303	17.72	13.98	3.74
304	19.93	16.86	3.07
306	17.75	17.00	0.75
307	15.35	14.91	0.44
308	17.72	14.14	3.58
311	15.90	14.28	1.62
312	14.31	15.13	-0.82
314	11.01	13.76	-2.75
315	9.54	13.78	-4.24
318	12.92	14.21	-1.29
319	15.35	14.75	0.60
320	17.72	14.45	3.27
322	24.68	25.67	-0.99
324	17.11	14.62	2.49
325	15.44	13.98	1.46
330	15.53	16.39	-0.86
332	14.77	13.72	1.05
334	15.35	14.81	0.54

**ANEXO N° 3. DATOS DE SALIDA DE LA DOSIS (ppm) EN EL
ENTRENAMIENTO Y PRUEBA DE RED NEURONAL DE TRES CAPAS CON
UNA OCULTA DE CINCO NEURONAS**

DATOS DE ENTRENAMIENTO Y PRUEBA							
RED DE CUATRO CAPAS (DOS CAPAS OCULTAS)							
Datos de entrenamiento				Datos de prueba			
N° Fila	Real	De predicción	Residual	N° Fila	Real	De predicción	Residual
6	8.63	10.14	-1.51	1	8.21	10.57	-2.36
7	9.15	10.13	-0.98	2	13.92	10.73	3.19
10	9.72	10.42	-0.70	3	12.29	10.88	1.41
11	12.97	9.13	3.84	4	11.85	10.99	0.86
12	10.82	9.58	1.24	5	9.15	10.13	-0.98
13	8.49	10.61	-2.12	8	8.21	10.57	-2.36
18	9.92	8.70	1.22	9	11.85	10.99	0.86
21	9.67	10.54	-0.87	14	9.15	10.13	-0.98
26	8.36	9.98	-1.62	15	9.15	10.13	-0.98
35	8.21	10.57	-2.36	16	9.12	9.12	0.00
36	8.46	9.86	-1.40	17	7.47	9.20	-1.73
41	11.85	10.99	0.86	19	9.15	10.13	-0.98
42	9.06	10.10	-1.04	20	8.63	10.14	-1.51
43	9.06	10.10	-1.04	22	9.06	10.10	-1.04
44	9.37	11.36	-1.99	23	11.85	10.99	0.86
46	6.87	11.39	-4.52	24	9.25	9.89	-0.64
47	4.94	11.29	-6.35	25	10.44	5.59	4.85
48	8.21	10.57	-2.36	27	8.77	9.91	-1.14
49	9.06	10.10	-1.04	28	9.06	10.10	-1.04
50	9.06	10.10	-1.04	29	8.21	10.57	-2.36
51	5.55	9.43	-3.88	30	8.21	10.57	-2.36
55	8.21	10.57	-2.36	31	8.17	10.31	-2.14
56	7.69	12.73	-5.04	32	9.35	9.92	-0.57
61	8.21	10.57	-2.36	33	11.85	10.99	0.86
64	9.06	10.10	-1.04	34	9.06	10.10	-1.04
65	11.13	11.54	-0.41	37	9.42	9.88	-0.46
66	11.44	13.52	-2.08	38	9.01	9.55	-0.54
69	9.06	10.10	-1.04	39	9.12	9.42	-0.30
71	11.04	10.66	0.38	40	9.06	10.10	-1.04
72	10.32	14.83	-4.51	45	7.24	11.76	-4.52
73	12.49	13.82	-1.33	52	8.00	9.65	-1.65
80	14.22	17.22	-3.00	53	7.36	9.64	-2.28
84	21.76	21.47	0.29	54	10.31	11.33	-1.02
85	21.76	21.47	0.29	57	8.35	12.03	-3.68

87	15.10	17.52	-2.42
90	21.76	21.47	0.29
94	18.09	17.40	0.69
98	20.97	15.34	5.63
99	21.99	15.97	6.02
102	20.97	15.34	5.63
105	14.22	17.22	-3.00
106	18.28	17.74	0.54
107	14.22	17.22	-3.00
115	17.45	14.20	3.25
121	22.91	17.35	5.56
122	19.54	12.22	7.32
127	18.28	18.27	0.01
128	19.00	21.07	-2.07
129	19.89	21.34	-1.45
131	19.18	19.24	-0.06
132	16.81	15.83	0.98
135	16.78	8.86	7.92
136	17.82	12.43	5.39
138	17.20	16.18	1.02
142	16.81	15.83	0.98
143	22.91	17.35	5.56
148	10.41	13.21	-2.80
152	19.18	19.24	-0.06
156	11.85	10.99	0.86
159	9.63	11.53	-1.90
160	8.28	14.37	-6.09
166	32.37	29.84	2.53
168	31.79	28.62	3.17
169	32.06	31.41	0.65
171	31.79	28.31	3.48
173	29.72	29.20	0.52
174	27.76	27.51	0.25
175	27.15	30.24	-3.09
177	31.79	28.62	3.17
179	31.79	28.31	3.48
180	18.28	17.74	0.54
181	14.29	18.91	-4.62
182	20.62	19.72	0.90
184	27.15	30.24	-3.09
189	32.06	29.25	2.81
196	14.29	18.91	-4.62
197	20.62	19.72	0.90
202	14.79	15.49	-0.70

58	9.69	11.28	-1.59
59	10.30	11.70	-1.40
60	7.99	11.36	-3.37
62	11.04	10.66	0.38
63	8.21	10.57	-2.36
67	8.19	12.84	-4.65
68	14.70	12.99	1.71
70	11.04	10.66	0.38
74	10.89	14.13	-3.24
75	11.41	14.64	-3.23
76	11.04	10.66	0.38
77	10.19	16.92	-6.73
78	10.22	15.65	-5.43
79	10.36	15.23	-4.87
81	13.21	16.09	-2.88
82	13.21	16.09	-2.88
83	14.22	17.22	-3.00
86	19.33	16.34	2.99
88	14.91	16.38	-1.47
89	18.28	17.74	0.54
91	18.28	18.83	-0.55
92	18.28	17.74	0.54
93	19.60	16.94	2.66
95	15.26	17.50	-2.24
96	19.60	16.87	2.73
97	23.21	17.65	5.56
100	23.62	16.61	7.01
101	23.21	17.65	5.56
103	21.93	14.73	7.20
104	16.14	14.19	1.95
108	15.70	13.63	2.07
109	17.09	12.85	4.24
110	15.52	13.81	1.71
111	12.92	12.59	0.33
112	18.28	17.74	0.54
113	11.04	10.66	0.38
114	17.82	12.43	5.39
116	17.20	16.18	1.02
117	19.60	16.45	3.15
118	18.28	17.74	0.54
119	19.18	19.24	-0.06
120	16.81	15.83	0.98
123	16.78	8.86	7.92
124	18.28	17.67	0.61

204	16.98	15.31	1.67
208	19.70	18.25	1.45
209	18.63	16.10	2.53
216	19.47	20.29	-0.82
220	27.15	29.11	-1.96
221	28.38	22.89	5.49
224	22.69	27.75	-5.06
232	21.49	17.32	4.17
234	17.72	13.52	4.20
240	24.27	22.80	1.47
242	24.68	25.67	-0.99
244	23.26	26.73	-3.47
247	24.68	25.67	-0.99
248	25.34	27.33	-1.99
249	27.03	30.27	-3.24
250	25.86	29.74	-3.88
251	22.90	23.36	-0.46
252	24.68	25.67	-0.99
253	21.64	21.26	0.38
261	18.28	15.89	2.39
264	17.99	20.35	-2.36
271	16.51	18.32	-1.81
273	17.15	17.19	-0.04
275	13.67	16.24	-2.57
276	13.34	15.67	-2.33
277	27.15	30.19	-3.04
279	32.06	29.25	2.81
280	24.68	25.67	-0.99
281	22.48	19.69	2.79
285	17.64	16.90	0.74
287	35.49	30.45	5.04
288	22.90	23.05	-0.15
289	24.68	25.67	-0.99
290	17.85	23.34	-5.49
294	24.68	25.57	-0.89
295	19.37	18.25	1.12
296	15.04	16.82	-1.78
297	20.52	18.97	1.55
299	19.99	16.74	3.25
301	17.78	18.63	-0.85
302	15.35	14.44	0.91
305	19.76	16.66	3.10
309	17.38	15.87	1.51
310	18.93	15.25	3.68

125	18.28	22.00	-3.72
126	14.22	17.22	-3.00
130	19.95	29.07	-9.12
133	22.91	17.35	5.56
134	19.54	12.22	7.32
137	17.45	14.20	3.25
139	22.91	17.35	5.56
140	11.04	11.78	-0.74
141	19.18	19.24	-0.06
144	11.04	11.78	-0.74
145	9.63	11.53	-1.90
146	8.28	14.37	-6.09
147	11.04	10.66	0.38
149	11.04	10.66	0.38
150	19.89	21.34	-1.45
151	19.95	29.07	-9.12
153	16.81	15.83	0.98
154	9.12	12.40	-3.28
155	8.02	13.02	-5.00
157	11.85	10.99	0.86
158	11.04	11.78	-0.74
161	11.04	10.66	0.38
162	10.41	13.21	-2.80
163	11.85	10.99	0.86
164	31.79	27.38	4.41
165	30.90	26.14	4.76
167	27.15	30.24	-3.09
170	30.93	31.62	-0.69
172	31.79	28.31	3.48
176	27.15	30.24	-3.09
178	32.06	29.25	2.81
183	21.28	20.77	0.51
185	22.52	24.02	-1.50
186	25.68	24.91	0.77
187	27.15	24.54	2.61
188	31.79	28.62	3.17
190	27.15	30.24	-3.09
191	15.35	20.08	-4.73
192	17.72	12.90	4.82
193	28.46	22.34	6.12
194	27.74	24.62	3.12
195	21.28	20.61	0.67
198	15.35	16.37	-1.02
199	17.72	14.29	3.43

313	10.32	14.19	-3.87
316	9.97	14.01	-4.04
317	10.37	13.89	-3.52
321	18.29	13.96	4.33
323	18.35	14.62	3.73
326	16.14	13.16	2.98
327	24.68	25.67	-0.99
328	13.12	13.52	-0.40
329	18.49	17.27	1.22
331	15.73	13.85	1.88
333	15.80	15.08	0.72
335	17.72	14.14	3.58

200	17.62	17.20	0.42
201	17.72	14.29	3.43
203	18.68	14.63	4.05
205	18.28	17.74	0.54
206	18.63	16.10	2.53
207	22.41	19.85	2.56
210	21.27	18.97	2.30
211	31.02	31.98	-0.96
212	18.58	20.52	-1.94
213	21.27	18.97	2.30
214	31.02	31.98	-0.96
215	25.04	25.75	-0.71
217	20.77	20.55	0.22
218	27.20	19.21	7.99
219	20.45	27.21	-6.76
222	20.45	27.21	-6.76
223	23.88	31.09	-7.21
225	22.32	24.98	-2.66
226	17.72	12.90	4.82
227	24.68	25.67	-0.99
228	20.86	29.78	-8.92
229	19.12	23.73	-4.61
230	19.71	18.08	1.63
231	19.16	19.43	-0.27
233	17.72	13.37	4.35
235	27.15	30.24	-3.09
236	23.83	19.98	3.85
237	23.88	20.95	2.93
238	22.90	24.59	-1.69
239	24.68	25.67	-0.99
241	19.73	23.66	-3.93
243	23.83	19.20	4.63
245	23.16	28.23	-5.07
246	24.68	25.67	-0.99
254	18.55	24.68	-6.13
255	16.46	23.61	-7.15
256	24.68	25.67	-0.99
257	24.68	25.67	-0.99
258	17.43	22.64	-5.21
259	22.90	23.36	-0.46
260	18.29	20.78	-2.49
262	18.24	25.99	-7.75
263	19.26	24.43	-5.17
265	17.00	17.51	-0.51

266	15.61	16.59	-0.98
267	16.50	16.97	-0.47
268	15.72	16.50	-0.78
269	16.73	16.74	-0.01
270	15.86	17.68	-1.82
272	16.67	17.14	-0.47
274	24.68	25.67	-0.99
278	31.79	28.62	3.17
282	13.34	18.86	-5.52
283	13.67	16.24	-2.57
284	14.87	17.44	-2.57
286	23.88	20.08	3.80
291	21.15	31.11	-9.96
292	19.69	22.95	-3.26
293	24.50	25.63	-1.13
298	18.44	18.20	0.24
300	18.64	18.95	-0.31
303	17.72	13.98	3.74
304	19.93	16.86	3.07
306	17.75	17.00	0.75
307	15.35	14.91	0.44
308	17.72	14.14	3.58
311	15.90	14.28	1.62
312	14.31	15.13	-0.82
314	11.01	13.76	-2.75
315	9.54	13.78	-4.24
318	12.92	14.21	-1.29
319	15.35	14.75	0.60
320	17.72	14.45	3.27
322	24.68	25.67	-0.99
324	17.11	14.62	2.49
325	15.44	13.98	1.46
330	15.53	16.39	-0.86
332	14.77	13.72	1.05
334	15.35	14.81	0.54

**ANEXO N° 4. DATOS DE SALIDA DE LA DOSIS (ppm) EN EL
ENTRENAMIENTO Y PRUEBA DE RED NEURONAL DE TRES CAPAS DE
REGRESIÓN GENERALIZADA (GRNN)**

<u>DATOS DE ENTRENAMIENTO Y PRUEBA</u>							
<u>RED TRES CAPAS (UNA OCULTA DE REGRESIÓN GENERALIZADA GRNN)</u>							
Datos de entrenamiento				Datos de prueba			
N° Fila	Real	De predicción	Residual	N° Fila	Real	De predicción	Residual
1	8.21	8.48	-0.27	2	13.92	8.67	5.25
5	9.15	8.75	0.40	3	12.29	9.57	2.72
6	8.63	8.80	-0.17	4	11.85	9.24	2.61
8	8.21	8.48	-0.27	7	9.15	8.75	0.40
10	9.72	9.44	0.28	9	11.85	9.24	2.61
11	12.97	9.75	3.22	12	10.82	9.01	1.81
13	8.49	8.76	-0.27	16	9.12	8.74	0.38
14	9.15	8.75	0.40	17	7.47	9.44	-1.97
15	9.15	8.75	0.40	22	9.06	9.19	-0.13
18	9.92	9.97	-0.05	23	11.85	9.24	2.61
19	9.15	8.75	0.40	24	9.25	8.76	0.49
20	8.63	8.80	-0.17	26	8.36	9.05	-0.69
21	9.67	9.23	0.44	27	8.77	9.08	-0.31
25	10.44	10.45	-0.01	28	9.06	9.19	-0.13
29	8.21	8.48	-0.27	30	8.21	8.48	-0.27
31	8.17	8.46	-0.29	32	9.35	8.95	0.40
34	9.06	9.19	-0.13	33	11.85	9.24	2.61
38	9.01	8.73	0.28	35	8.21	8.48	-0.27
39	9.12	9.22	-0.10	36	8.46	8.86	-0.40
43	9.06	9.19	-0.13	37	9.42	8.84	0.58
47	4.94	7.46	-2.52	40	9.06	9.19	-0.13
48	8.21	8.48	-0.27	41	11.85	9.24	2.61
49	9.06	9.19	-0.13	42	9.06	9.19	-0.13
52	8.00	9.20	-1.20	44	9.37	9.28	0.09
55	8.21	8.48	-0.27	45	7.24	9.30	-2.06
56	7.69	7.89	-0.20	46	6.87	9.29	-2.42
58	9.69	9.50	0.19	50	9.06	9.19	-0.13
59	10.30	10.30	0.00	51	5.55	9.36	-3.81
61	8.21	8.48	-0.27	53	7.36	8.70	-1.34
63	8.21	8.48	-0.27	54	10.31	10.30	0.01
65	11.13	9.02	2.11	57	8.35	8.90	-0.55
67	8.19	8.04	0.15	60	7.99	8.50	-0.51
69	9.06	9.19	-0.13	62	11.04	11.04	0.00
71	11.04	11.04	0.00	64	9.06	9.19	-0.13

76	11.04	11.04	0.00
78	10.22	13.43	-3.21
85	21.76	21.62	0.14
86	19.33	19.33	0.00
88	14.91	14.91	0.00
91	18.28	18.28	0.00
95	15.26	16.65	-1.39
97	23.21	23.21	0.00
98	20.97	20.97	0.00
99	21.99	21.29	0.70
101	23.21	23.21	0.00
102	20.97	20.97	0.00
106	18.28	18.15	0.13
109	17.09	17.37	-0.28
112	18.28	18.15	0.13
116	17.20	16.97	0.23
121	22.91	22.78	0.13
122	19.54	19.53	0.01
123	16.78	16.78	0.00
124	18.28	18.53	-0.25
125	18.28	18.42	-0.14
129	19.89	19.89	0.00
130	19.95	19.95	0.00
132	16.81	15.62	1.19
133	22.91	22.78	0.13
136	17.82	17.54	0.28
152	19.18	19.18	0.00
153	16.81	15.62	1.19
158	11.04	11.04	0.00
161	11.04	11.04	0.00
162	10.41	10.41	0.00
168	31.79	31.79	0.00
172	31.79	31.79	0.00
173	29.72	29.81	-0.09
174	27.76	27.76	0.00
177	31.79	31.79	0.00
179	31.79	31.79	0.00
181	14.29	14.29	0.00
182	20.62	20.70	-0.08
188	31.79	31.79	0.00
189	32.06	32.06	0.00
203	18.68	18.62	0.06
204	16.98	16.99	-0.01
205	18.28	18.15	0.13

66	11.44	13.44	-2.00
68	14.70	8.57	6.13
70	11.04	11.04	0.00
72	10.32	20.99	-10.67
73	12.49	15.91	-3.42
74	10.89	18.72	-7.83
75	11.41	20.63	-9.22
77	10.19	18.49	-8.30
79	10.36	17.59	-7.23
80	14.22	16.28	-2.06
81	13.21	14.92	-1.71
82	13.21	14.92	-1.71
83	14.22	16.28	-2.06
84	21.76	21.62	0.14
87	15.10	14.93	0.17
89	18.28	18.15	0.13
90	21.76	21.62	0.14
92	18.28	18.15	0.13
93	19.60	15.86	3.74
94	18.09	19.32	-1.23
96	19.60	15.79	3.81
100	23.62	16.03	7.59
103	21.93	16.54	5.39
104	16.14	9.78	6.36
105	14.22	16.28	-2.06
107	14.22	16.28	-2.06
108	15.70	16.45	-0.75
110	15.52	17.26	-1.74
111	12.92	10.67	2.25
113	11.04	11.04	0.00
114	17.82	17.54	0.28
115	17.45	11.12	6.33
117	19.60	15.63	3.97
118	18.28	18.15	0.13
119	19.18	19.18	0.00
120	16.81	15.62	1.19
126	14.22	16.28	-2.06
127	18.28	18.36	-0.08
128	19.00	22.91	-3.91
131	19.18	19.18	0.00
134	19.54	19.53	0.01
135	16.78	16.78	0.00
137	17.45	11.12	6.33
138	17.20	16.97	0.23

208	19.70	19.59	0.11
211	31.02	31.02	0.00
220	27.15	27.15	0.00
223	23.88	23.88	0.00
224	22.69	22.83	-0.14
225	22.32	22.32	0.00
229	19.12	19.12	0.00
232	21.49	21.49	0.00
235	27.15	27.15	0.00
236	23.83	23.83	0.00
242	24.68	24.68	0.00
243	23.83	23.83	0.00
244	23.26	23.26	0.00
245	23.16	23.16	0.00
246	24.68	24.68	0.00
247	24.68	24.68	0.00
248	25.34	25.20	0.14
255	16.46	16.46	0.00
256	24.68	24.68	0.00
258	17.43	17.43	0.00
261	18.28	18.28	0.00
264	17.99	18.09	-0.10
265	17.00	17.00	0.00
269	16.73	16.73	0.00
273	17.15	17.18	-0.03
277	27.15	27.15	0.00
278	31.79	31.79	0.00
281	22.48	22.40	0.08
282	13.34	13.34	0.00
283	13.67	13.67	0.00
285	17.64	17.64	0.00
288	22.90	22.90	0.00
289	24.68	24.68	0.00
290	17.85	17.85	0.00
292	19.69	19.69	0.00
295	19.37	17.60	1.77
296	15.04	16.82	-1.78
298	18.44	18.44	0.00
299	19.99	19.99	0.00
300	18.64	18.64	0.00
302	15.35	15.30	0.05
303	17.72	17.43	0.29
304	19.93	19.90	0.03
306	17.75	17.75	0.00

139	22.91	22.78	0.13
140	11.04	11.04	0.00
141	19.18	19.18	0.00
142	16.81	15.62	1.19
143	22.91	22.78	0.13
144	11.04	11.04	0.00
145	9.63	11.04	-1.41
146	8.28	20.97	-12.69
147	11.04	11.04	0.00
148	10.41	10.41	0.00
149	11.04	11.04	0.00
150	19.89	19.89	0.00
151	19.95	19.95	0.00
154	9.12	10.84	-1.72
155	8.02	18.29	-10.27
156	11.85	9.24	2.61
157	11.85	9.24	2.61
159	9.63	11.04	-1.41
160	8.28	20.97	-12.69
163	11.85	9.24	2.61
164	31.79	31.78	0.01
165	30.90	29.89	1.01
166	32.37	27.77	4.60
167	27.15	27.15	0.00
169	32.06	32.06	0.00
170	30.93	29.73	1.20
171	31.79	31.79	0.00
175	27.15	27.15	0.00
176	27.15	27.15	0.00
178	32.06	32.06	0.00
180	18.28	18.15	0.13
183	21.28	20.73	0.55
184	27.15	27.15	0.00
185	22.52	29.72	-7.20
186	25.68	29.71	-4.03
187	27.15	24.67	2.48
190	27.15	27.15	0.00
191	15.35	10.43	4.92
192	17.72	17.67	0.05
193	28.46	29.72	-1.26
194	27.74	22.31	5.43
195	21.28	16.83	4.45
196	14.29	14.29	0.00
197	20.62	20.70	-0.08

308	17.72	17.36	0.36
310	18.93	18.64	0.29
311	15.90	15.90	0.00
313	10.32	10.89	-0.57
315	9.54	10.23	-0.69
319	15.35	15.24	0.11
322	24.68	24.68	0.00
323	18.35	18.33	0.02
325	15.44	15.50	-0.06
329	18.49	18.49	0.00
332	14.77	14.80	-0.03
333	15.80	15.75	0.05

198	15.35	18.43	-3.08
199	17.72	17.27	0.45
200	17.62	17.69	-0.07
201	17.72	17.27	0.45
202	14.79	18.42	-3.63
206	18.63	17.61	1.02
207	22.41	18.09	4.32
209	18.63	17.61	1.02
210	21.27	20.70	0.57
212	18.58	18.83	-0.25
213	21.27	20.70	0.57
214	31.02	31.02	0.00
215	25.04	19.69	5.35
216	19.47	14.42	5.05
217	20.77	18.44	2.33
218	27.20	18.22	8.98
219	20.45	27.77	-7.32
221	28.38	19.26	9.12
222	20.45	27.77	-7.32
226	17.72	17.67	0.05
227	24.68	24.68	0.00
228	20.86	23.88	-3.02
230	19.71	17.00	2.71
231	19.16	23.83	-4.67
233	17.72	17.61	0.11
234	17.72	17.58	0.14
237	23.88	22.90	0.98
238	22.90	22.90	0.00
239	24.68	24.68	0.00
240	24.27	23.83	0.44
241	19.73	23.69	-3.96
249	27.03	23.80	3.23
250	25.86	23.16	2.70
251	22.90	22.90	0.00
252	24.68	24.68	0.00
253	21.64	17.26	4.38
254	18.55	16.46	2.09
257	24.68	24.68	0.00
259	22.90	22.90	0.00
260	18.29	23.82	-5.53
262	18.24	18.65	-0.41
263	19.26	23.52	-4.26
266	15.61	19.99	-4.38
267	16.50	17.00	-0.50

268	15.72	18.60	-2.88
270	15.86	17.00	-1.14
271	16.51	20.42	-3.91
272	16.67	17.15	-0.48
274	24.68	24.68	0.00
275	13.67	13.67	0.00
276	13.34	13.67	-0.33
279	32.06	32.06	0.00
280	24.68	24.68	0.00
284	14.87	17.58	-2.71
286	23.88	18.28	5.60
287	35.49	19.69	15.80
291	21.15	23.88	-2.73
293	24.50	24.68	-0.18
294	24.68	24.68	0.00
297	20.52	14.30	6.22
301	17.78	18.92	-1.14
305	19.76	17.74	2.02
307	15.35	15.21	0.14
309	17.38	19.92	-2.54
312	14.31	16.76	-2.45
314	11.01	14.97	-3.96
316	9.97	18.37	-8.40
317	10.37	18.32	-7.95
318	12.92	18.39	-5.47
320	17.72	17.16	0.56
321	18.29	18.44	-0.15
324	17.11	15.40	1.71
326	16.14	14.76	1.38
327	24.68	24.68	0.00
328	13.12	14.32	-1.20
330	15.53	18.63	-3.10
331	15.73	18.42	-2.69
334	15.35	15.14	0.21
335	17.72	17.36	0.36