

**UNIVERSIDAD CATÓLICA DE CUENCA**  
*Comunidad Educativa al Servicio del Pueblo*



**UNIDAD ACADÉMICA DE INGENIERÍA, INDUSTRIA Y  
CONSTRUCCIÓN**

**CARRERA DE INGENIERÍA AMBIENTAL**

**OPTIMIZACIÓN DE BIOPOLÍMEROS EN EL PROCESO DE  
COAGULACIÓN FLOCULACIÓN PARA EL TRATAMIENTO DE  
LIXIVIADOS EN LA CIUDAD DE CUENCA MEDIANTE EL USO  
DE REDES NEURONALES ARTIFICIALES**

**TRABAJO DE INVESTIGACIÓN PREVIO A LA OBTENCIÓN DEL  
TÍTULO DE INGENIERO AMBIENTAL**

**AUTOR: CARLOS ANDRES VALDIVIESO VALVERDE**

**DIRECTOR: ING. CARLOS MARCELO MATOVELLE BUSTOS**

**CUENCA**

**2019**

## DECLARACIÓN

Yo, Carlos Andrés Valdivieso Valverde, declaro bajo juramento que el trabajo aquí descrito es de mi autoría; que no ha sido previamente presentada para ningún grado o calificación profesional; y, que he consultado las referencias bibliográficas que se incluyen en este documento; y eximo expresamente a la Universidad Católica de Cuenca y a sus representantes legales de posibles reclamos o acciones legales.

La Universidad Católica de Cuenca puede hacer uso de los derechos correspondientes a este trabajo, según lo establecido por la Ley de Propiedad Intelectual, por su Reglamento y la normatividad institucional vigente.



---

**Carlos Andrés Valdivieso Valverde**

## CERTIFICACIÓN

Certifico que el presente trabajo fue desarrollado por Carlos Andrés Valdivieso Valverde, bajo mi supervisión.



---

**Ing. Carlos Marcelo Matovelle Bustos**

**0302013578**

**DIRECTOR**

## **AGRADECIMIENTOS**

Primero agradecer a Dios, por toda la sabiduría, confianza y la fuerza necesaria que me ayudo a seguir en los momentos más difíciles.

A mi familia y amigos que han estado en los momentos tanto buenos como en los malos, por todo el apoyo a lo largo de la vida estudiantil.

Así mismo a mi tutor el Ing. Carlos Marcelo Matovelle, por su paciencia, dedicación, esfuerzo y conocimientos brindados a lo largo del proyecto de tesis y su comprensión para la dirección del trabajo

Agradezco a la Universidad Católica de Cuenca y todos los docentes de la carrera de Ingeniera Ambiental que han sabido y guiarme por el camino del conocimiento.

## DEDICATORIA

Este trabajo va dedicado, a Dios por no permitirme desmayar ante las adversidades que día a día se presentaron.

A mis queridos padres, El Ing. Carlos Valdivieso y la Lcda. Mariana Valverde que han sido las piezas claves en toda mi vida, me guiaron, me dieron todos los consejos, enseñanzas y todo su esfuerzo por todo el amor incondicional ya que gracias a ellos he podido llegar a estas instancias y ser la persona de bien que han formado a lo largo de la vida.

A mis hermanas a quienes quiero mucho y espero ser un ejemplo en sus vidas para que logren todas sus metas.

A Michelle por ser la persona que ha estado apoyándome en toda esta etapa de gran importancia en mi vida, por haberme brindado su dedicación, paciencia y amor en todos los momentos.

A mis amigos y a todas las personas de mi vida que han estado de una u otra forma dándome todo su apoyo en esta etapa. Sencillamente gracias de todo corazón.

## ÍNDICE DE CONTENIDOS

DECLARACIÓN.....	I
CERTIFICACIÓN.....	II
AGRADECIMIENTOS.....	III
DEDICATORIA .....	IV
ÍNDICE DE CONTENIDOS.....	V
LISTA DE FIGURAS .....	VIII
LISTA DE TABLAS.....	IX
LISTA DE CODIGOS .....	X
LISTA DE FORMULAS.....	XI
RESUMEN.....	XII
ABSTRACT .....	XIII
CAPÍTULO I.....	1
1. INTRODUCCION.....	1
1.1. Objetivos .....	3
1.1.1. Objetivo general.....	3
1.1.2. Objetivos específicos .....	4
CAPÍTULO II .....	5
2. MARCO TEORICO.....	5
2.1. Lixiviados .....	5
2.2. Coagulación y Floculación .....	5
2.2.1. Coagulación.....	6
2.2.2. Floculación.....	7
2.3. Factores que influyen en el proceso de coagulación- floculación .....	7
2.4. Coagulantes químicos .....	8
2.5. Cloruro férrico. ....	9
2.5.1. Aplicaciones del cloruro férrico. ....	9
2.6. Coagulantes naturales.....	9
2.6.1. Tipos de biopolímeros naturales.....	10
2.7. Almidón de yuca. ....	10
2.7.1. Componentes del almidón. ....	11

2.7.2.	Amilosa .....	11
2.7.3.	Amilopectina.....	11
2.8.	Máquinas de aprendizaje .....	12
2.8.1.	Diseño.....	12
2.8.2.	Entrenamiento.....	12
2.9.	Algoritmos de Machine Learning.....	12
2.10.	Algoritmos para las máquinas de aprendizaje .....	13
2.10.1.	Aprendizaje supervisado.....	13
2.10.2.	Aprendizaje no supervisado.....	13
2.11.	Selección de algoritmos lineales.....	13
2.11.1.	Algoritmo de Regresión Lineal (LR). .....	13
2.11.2.	Algoritmo de Regresión Lineal Generalizado (GLM). .....	13
2.11.3.	Algoritmo de Regresión Lineal Penalizada (GLMNET). .....	14
2.12.	Selección de algoritmos no lineales .....	14
2.12.1.	Algoritmo K Nearest Neighbors (K-NN). .....	14
2.12.2.	Algoritmo Support Vector Machines (SVM).....	14
2.12.3.	Algoritmo Classification and Regression Trees (CART). .....	15
2.13.	Métricas de regresión .....	15
2.14.	Optimización.....	15
CAPÍTULO III .....		16
3.	MATERIALES Y METODOS .....	16
3.1.	Zona de estudio .....	16
3.2.	Toma de muestras.....	17
3.3.	Sistema de toma de muestras.....	17
3.4.	Parámetros fisicoquímicos que intervienen en la coagulación – floculación ...	18
3.5.	Pruebas de laboratorio .....	19
3.5.1.	Obtención del almidón de yuca.....	20
3.5.2.	Preparación del cloruro férrico. ....	21
3.5.3.	Ensayo de jarras.....	21
3.6.	Metodología de aplicación de máquinas de aprendizaje .....	22
CAPÍTULO IV.....		26
4.	RESULTADOS Y DISCUSIÓN.....	26
4.1.	Extracción del almidón de yuca.....	26

4.2.	Prueba de jarras .....	26
4.3.	Resultados de la medición de turbidez, solidos, pH .....	27
4.3.1.	Turbidez.....	27
4.3.2.	El pH.....	29
4.3.3.	Sólidos.....	30
4.4.	Resultados afines de la dosis óptima de coagulante.....	30
4.5.	Resultados de optimización con máquinas de aprendizaje.....	34
4.5.1.	Preprocesamiento de datos.....	34
4.5.2.	Correlación de las variables.....	34
4.5.3.	División del set de entrenamiento y validación de datos.....	36
4.5.4.	Implementación de la máquina de aprendizaje y evaluación de las métricas de regresión.....	36
4.5.5.	Fase de Optimización.....	39
4.5.6.	Validación de datos para la máquina de aprendizaje.....	39
4.5.7.	Fase de Forecasting.....	41
CAPÍTULO V .....		43
5.	CONCLUSIONES.....	43
CAPÍTULO VI.....		45
6.	RECOMENDACIONES.....	45
REFERENCIAS BIBLIOGRAFICAS .....		47
ANEXOS .....		51
	Anexo 1. Registro Fotográfico.....	51
	Anexo 2. Tablas.....	57

## LISTA DE FIGURAS

Figura 1. Desestabilización de las cargas en la coagulación.....	6
Figura 2. Ubicación del Relleno Sanitario "Pichacay". .....	17
Figura 3. Toma de muestras dentro del relleno.....	18
Figura 4. Preparación del cloruro férrico .....	21
Figura 5. Jar Test (Ensayo de Jarras). .....	22
Figura 6. Prueba de jarras adicionando biopolímeros.....	27
Figura 7. Medición de turbidez (Turbidímetro).....	29
Figura 8. Medición de pH (pH-metro).....	29
Figura 9. Sólidos suspendidos (Desecador). .....	30
Figura 10. Gráfico turbidez en función de dosis de cloruro (de 8 a 22 ml). .....	31
Figura 11. Gráfico turbidez en función de dosis de cloruro (de 3 a 17 ml). .....	32
Figura 12. Gráfico turbidez en función de dosis de cloruro (de 0,5 a 13 ml). .....	33
Figura 13. Relación de parámetros de la maquinas de aprendizaje.....	35
Figura 14. Métricas de Regresión.....	38
Figura 15. Datos observados en función de datos simulados por la máquina de aprendizaje.....	40

## LISTA DE TABLAS

Tabla 1. Porcentaje de remoción.....	28
Tabla 2. Ensayos de turbidez en función del cloruro (de 8 a 22 ml).....	31
Tabla 3. Ensayos de turbidez en función del cloruro (de 3 a 17 ml).....	32
Tabla 4. Ensayos de turbidez en función del cloruro (de 0,5 a 13 ml).....	32
Tabla 5. Relación numérica de parámetros de las máquinas de aprendizaje.....	35
Tabla 6. Métricas de regresión MAE, RMSE y Rsquared.....	37
Tabla 7. Verificación de datos observados en función de datos simulados en la máquina de aprendizaje.....	39
Tabla 8. Datos predichos de las dosis de cloruro.....	41

## LISTA DE CODIGOS

Código 1. Cargar el conjunto de datos de Prueba.....	23
Código 2. Correlaciones entre variables.....	23
Código 3. División de datos.....	24
Código 3. Algoritmos lineales y no lineales.....	25

## LISTA DE FORMULAS

Fórmula 1. Fórmula del porcentaje de remoción.....	28
--	----

## RESUMEN

Los vertidos de lixiviados provenientes de los rellenos sanitarios contienen gran cantidad de carga de contaminantes que resultan perjudiciales para el medio ambiente, los tratamientos que se les dan son escasos en nuestro medio, por lo que el presente estudio se desarrolló con el fin de determinar las dosis de biopolímeros adecuadas para los procesos de coagulación-floculación en su tratamiento. La herramienta que se utilizó para tal efecto fueron los modelos computacionales como son la Redes Neuronales Artificiales (RNA), estos permiten disminuir las operaciones de los ensayos de jarras en el laboratorio; optimizando los recursos. Mediante la experimentación en laboratorio se tuvieron resultados reales de la efectividad de la aplicación de biopolímeros en los tratamientos de lixiviados.

Los resultados de laboratorio fueron tomados como variables de entrada de la RNA y se procedió a estimar datos en forma predictiva, con el modelo computacional que determina la dosis óptima para el tratamiento que se realiza. Por otro lado, se comprobó que los tratamientos aplicados de coagulación - floculación reduce los valores de turbidez en el lixiviado y de esta manera los ensayos de jarras se optimizan de tal forma que los costos operacionales también disminuyen.

**PALABRAS CLAVES:** VERTIDOS DE LIXIVIADOS, BIOPOLIMEROS, COAGULACION-FLOCULACION, REDES NEURONALES ARTIFICIALES, ENSAYOS DE JARRAS

## **ABSTRACT**

Leachate discharges from landfills include large amounts of pollutant loads which are hazardous to the environment, the treatments they receive are limited, so this research was developed in order to determine the appropriate doses of biopolymers for the coagulation-flocculation processes in the treatment of leachate by using computer models such as Artificial Neural Networks (ANN), allowing to reduce the laboratory jug testing operations; optimizing the resources. Through laboratory experimentation, real results of the effectiveness of applying biopolymers in leachate treatments.

The laboratory results were used as input variables for the ANN and the predicted data was then estimated with the computer model, which determined that the projected doses are suitable for the treatment in question. It was proven that the coagulation-flocculation treatments applied reduce the turbidity values in the leachate and thus the jar tests are being optimized so that the operating costs are being reduced.

**KEYWORDS:** LEACHATE DISCHARGES, BIOPOLYMERS, COAGULATION-FLOCCULATION, ARTIFICIAL NEURAL NETWORKS, JAR TESTS

# CAPÍTULO I

## 1. INTRODUCCION

La disposición final en los rellenos sanitarios es uno de los métodos más aceptados en muchos países para eliminar los residuos sólidos urbanos, los mismos que han pasado por todo el ciclo dentro del relleno, incluyendo una parte principal en donde el agua que ha entrado en contacto con la basura que recoge gran cantidad de las sustancias, esta agua se conoce como lixiviado y es uno de los líquidos más contaminantes. De no acopiarlo y luego tratarlo, el lixiviado puede contaminar aguas subterráneas, aguas superficiales y suelos. Para realizar cualquier tipo de tratamiento del agua se deben tener en consideración criterios como: características físicas, características químicas, tamaño de partículas suspendidas, coloidales y disueltas en el agua, de esta forma se puede determinar que tratamiento es el óptimo para aplicarlo al lixiviado.

Con el propósito de reducir la contaminación del medio ambiente por la disposición final de los desechos sólidos, es preciso que tengan el conocimiento de la cantidad y calidad que esperan del lixiviado generado.

La calidad de los lixiviados en un relleno sanitario varía ampliamente en el tiempo, al igual que, con el tipo de relleno sanitario que se cuenta. Vale la pena indicar las diferencias que se tienen en las calidades de los lixiviados entre los países desarrollados con los de los países en vía de desarrollo, se puede señalar que los lixiviados de los rellenos sanitarios de países en desarrollo presentan concentraciones mucho mayores de materia orgánica, pH, sólidos suspendidos y hasta metales pesados a diferencia de aquellos países desarrollados, en la ciudad de Cuenca en el relleno sanitario de Pichacay el volumen de lixiviados que se genera es de 100 m<sup>3</sup>/día<sup>1</sup>.

Para el tratamiento de aguas usualmente utilizan coagulantes y floculantes metálicos como el cloruro férrico, pero con el tiempo han nacido diferentes alternativas como lo son los coagulantes orgánicos, que conservan la misma efectividad al momento de

---

<sup>1</sup> EMAC. (s.f.). Relleno Sanitario de Pichacay | EMAC - EMPRESA PÚBLICA MUNICIPAL DE ASEO DE CUENCA. Recuperado 8 enero, 2020, de <http://www.emac.gob.ec/?q=content/relleno-sanitario-de-pichacay>

realizar la remoción de turbiedad y color, conjuntamente son económicos y accesibles siendo este un método viable para economías de países en vías de desarrollo.

Los coagulantes son productos de origen químicos que se adicionan al agua y producen reacciones químicas con los diferentes componentes químicos que se encuentran en el agua, de tal manera que con la alcalinidad del agua se forma un precipitado voluminoso, constituido por hidróxido metálico del coagulante que se esté utilizando (Arboleda, 2016).

“El almidón es el principal reservorio energético de los vegetales y proporciona una fuente de energía para los seres vivos que se alimentan de ellos. Se trata de un polisacárido conformado por dos polímeros que son la amilosa y la amilopectina cuya proporción varía según de donde se la obtiene. Así mismo existen estudios en donde se utiliza el almidón de yuca como agente floculante en la que se forman los puentes de polímeros obteniendo buenos resultados en remoción de color y turbiedad” (Bravo, 2017).

La materia orgánica que contiene el lixiviado produce el consumo de oxígeno disuelto en el mismo, generando olores desagradables, sobre todo en condiciones sépticas en las que siempre está el déficit de oxígeno causado por la misma, en donde se considera el factor más importante a tomar en cuenta en un relleno sanitario, además de eso, el alto porcentaje de esta materia entre los residuos, favorece la propagación de roedores, insectos y aves de carroña, asociados a la transmisión de enfermedades y epidemias, también da un impacto estético negativo en el paisaje próximo de los sitios de disposición final.

Las máquinas de aprendizaje son sistemas que aprenden de la experiencia, es decir aprenden diferentes tareas mediante un entrenamiento. Por medio del proceso de entrenamiento o aprendizaje, las máquinas de aprendizaje entienden su propia representación del problema, consecutivamente, pueden responder adecuadamente cuando se les presentan escenarios a las que no habían sido expuestas anteriormente, las máquinas de aprendizaje son capaces de sistematizar de casos anteriores a casos nuevos.

Para disminuir la carga contaminante, la materia orgánica excesiva, color y turbidez del lixiviado, deberán aplicar los biopolímeros en los procesos de coagulación-floculación, estos procesos podrán ser mejorados u optimizados mediante las redes neuronales (inteligencia artificial).

Para tener una mejor idea de cómo se plantea con la legislación se detalla un análisis un artículo del (COOTAD, 2010): los Gobiernos Autónomos Descentralizados Metropolitanos y Municipales al tratarse de materia ambiental, deben ejercer las siguientes facultades, en correlación con las políticas y normas emitidas por los Gobiernos Autónomos Provinciales y la Autoridad Ambiental Nacional: Elaborar planes, programas y proyectos para los sistemas de recolección, transporte, tratamiento y disposición final de residuos o desechos sólidos.

El relleno sanitario de Pichacay que está ubicado en la parroquia Santa Ana, a 21 Km de la ciudad de Cuenca. Inicio su operación el 3 de septiembre de 2001 cumpliendo estrictas normas previstas para este tipo de equipamientos sanitarios. El 14 de diciembre de 2002, el Ministerio del Ambiente, le otorgó la licencia ambiental. Por sus características técnicas, ambientales, de y seguridad y salud ocupacional mantiene un sistema integrado de gestión en base a las normas internacionales ISO 9001, ISO 14001 BSI OHSAS 18001.

Todos estos procesos se deben dar de la mano del avance de la tecnología, mediante el uso de las máquinas de aprendizaje se podrá mejorar la capacidad de calcular una buena optimización de las dosis en el proceso de coagulación-floculación así disminuyendo el uso de los ensayos de Jar-Test que se deben realizar para determinar la dosificación de los biopolímeros que es un proceso más largo. Al aplicar las máquinas de aprendizaje se tendrá mayor certeza de dicha dosificación y tener menor margen de error que proceso de él Jar-Test antes mencionado y algo importante es que se logra disminuir los costos de operación en el relleno sanitario.

## **1.1. Objetivos**

### **1.1.1. Objetivo general**

- Determinar la dosificación de biopolímeros en el proceso de coagulación-floculación en el tratamiento de lixiviados por medio del uso de Redes Neuronales Artificiales.

### **1.1.2. Objetivos específicos**

- Determinar el tipo de coagulante o biopolímero que es mejor aplicar en el proceso de coagulación-floculación.
- Obtener el almidón de yuca, biopolímero que se encuentra en las raíces de la yuca, mediante ensayos de laboratorio.
- Determinar la dosis optima de coagulantes por medio de la implementación de las Redes Neuronales Artificiales.

## **CAPÍTULO II**

### **2. MARCO TEORICO**

#### **2.1. Lixiviados**

El lixiviado es un líquido que ha percolado a través del desecho sólido y de esta manera arrastra materiales disueltos o suspendidos de ellos. En la mayoría de los rellenos sanitarios la porción líquida del lixiviado se compone del líquido derivado de la descomposición de los desechos y líquido que entra al relleno de fuentes ajenas como: drenaje superficial, precipitación, agua subterránea y agua de manantiales subterráneos (Tchobanoglous, Theissen, & Eliassen, 1982).

El agua entra en contacto con el residuo y forma los lixiviados por caminos como: agua infiltrada a través del material de recubrimiento, agua que inunda el muro del vertedero por elevación de los niveles freáticos, agua circulando horizontalmente por lados del vertedero, agua que existe en la zona de vertido o caída durante las operaciones. (Lopez, 2017).

La cantidad y calidad del lixiviado estarán determinadas por las características geológicas de la localización del vertedero y las condiciones meteorológicas que determinarán la disponibilidad de agua, así como las características de los residuos, la superficie del relleno el suelo subyacente, los procedimientos de explotación y los tratamientos de eliminación a los que se sometan los residuos (Tatsi & Zouboulis, 2002).

La composición de los lixiviados no se puede generalizar, pues depende de las características del residuo, orgánico-inorgánico, soluble/insoluble, degradable-biodegradable (Lopez, 2017).

#### **2.2. Coagulación y Floculación**

La coagulación y la floculación son dos procesos que se realizan uno seguido del otro, ya que son operaciones que intervienen en los procesos de tratamientos de agua con el fin de remover la turbiedad o sólidos suspendidos, así como también la remoción de color, eliminación de virus y microorganismos que muestren respuesta a estos procesos y también favorecen con la pérdida de sustancias que producen olor y sabor.

La coagulación interviene sobre la desestabilización de la suspensión coloidal, mientras que la floculación se localiza en el proceso de transporte de las partículas coaguladas y provocar colisiones entre ellas causando su aglomeración (Asano, 2014).

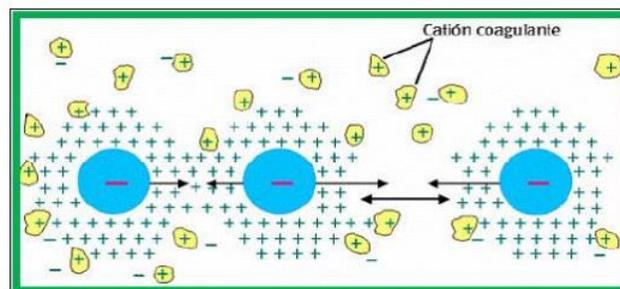
### 2.2.1. Coagulación.

“La coagulación es un proceso de desestabilización química de las partículas coloidales que se originan al neutralizar las fuerzas que los mantienen separados, por medio de la adición de los coagulantes químicos o naturales” (Abdon, 2012).

“La desestabilización de las partículas se da por efecto de la neutralización entre las cargas de las partículas que generalmente son negativas y de las sustancias químicas añadidas (positivas)” (Salazar, Rojas, & Carrilo, 2016).

Este proceso es utilizado para: remoción de turbiedad que no se puede sedimentar velozmente, remoción de color verdadero y aparente, eliminación de sabor, olor y precipitados químicos suspendidos en otros y destrucción de algas, plancton en general.

Las partículas que constituyen el color y la turbiedad de las aguas, contienen cargas eléctricas que son negativas, pero también cargas positivas. Las cargas eléctricas de las partículas crean fuerzas de repulsión entre las mismas, por lo cual se conservan suspendidas y separadas en el agua. (Hernan, 2009).



**Figura 1. Desestabilización de las cargas en la coagulación.**

**Fuente:** (Romero, 2012)

“Los coagulantes pueden clasificarse en tres grandes grupos: Los coagulantes metálicos, los coagulantes de origen vegetal y los polielectrolitos o ayudantes de coagulación. Los dos primeros actúan durante el proceso de coagulación, mientras que

los ayudantes ejercen su efecto en la floculación, contribuyendo con la formación de flóculos más pesados” (Castrillon & Giraldo, 2012).

También es común el uso de los coagulantes vegetales como coadyuvantes en el proceso de coagulación, dando como resultado la formación de flóculos con mejores características de sedimentación (Solis, Laines, & Hernández, 2012).

### **2.2.2. Floculación.**

La floculación es el proceso que le sigue a la coagulación, consiste en la agitación de la masa coagulada que permite el crecimiento y aglomeración de los flóculos recién formados con la finalidad de aumentar el tamaño y peso que son necesarios para sedimentar. Estos flóculos inicialmente pequeños se crean al juntarse aglomerados mayores que son capaces de sedimentar (Asano, 2004).

La floculación tiene como objetivo el aglutinamiento de los micro flóculos para que de esta manera se conforme las partículas con un peso superior al del agua en la que se encuentren y los flocs se compacten, reduciendo así el grado de hidratación para incitar a una menor concentración volumétrica y así se el agua y los flocs cumplen el proceso de separación. (Hernan, 2009)

“Cuando se añaden los coagulantes a una suspensión coloidal, se inician una serie de reacciones que fijan iones a la superficie de las partículas en la suspensión, las cuales pueden unirse para formar flóculos que crecen en función del tiempo. La rapidez con la que ocurre el proceso de floculación depende del tamaño de las partículas en relación a la agitación del agua a tratar, de la concentración de las partículas y del grado de desestabilización, el cual permite que sean efectivas las colisiones para producir adherencia de las partículas” (Hernan, 2009).

### **2.3. Factores que influyen en el proceso de coagulación- floculación**

Según (Salazar, Rojas, & Carrilo, 2016) y (Jimenez & Medina, 2017) existen diferentes factores que influyen directamente en el proceso de coagulación-floculación que son:

- **Influencia del pH:** El rango óptimo de pH para que se lleve a cabo una coagulación rápida y eficaz depende de la naturaleza del agua a tratar. Cuando se emplean sustancias químicas (coagulantes) como, sales de Aluminio es

necesario que el agua tenga un pH comprendido entre 6,5 y 8,5 y en el caso que se trabaje con sales de Hierro, el pH del agua deberá estar entre 5,5 y 8,5

- **Influencia de la Temperatura:** a menor temperatura del agua, más lento el proceso de formación del floc debido a que afecta a la energía cinética de las partículas que se hallan en suspensión, dando como resultado menor número de colisiones entre las mismas, y por consiguiente, se requiere de mayor tiempo para la formación del floc
- **Influencia de la Turbiedad:** considerado como un indicador de la medida de la concentración de sustancias coloidales insolubles en el agua.
- **Influencia del coagulante:** cuando se incorpora un exceso de coagulante, se genera una mayor cantidad de micro flóculos que tienen tamaños muy pequeños impidiendo la sedimentación rápida, debido a la inversión de la carga.
- **Influencia de la mezcla:** debe ser una agitación uniforme e intensa con la finalidad de garantizar una mezcla perfecta entre el coagulante y el agua.
- **Influencia del tamaño de la partícula:** tamaños comprendidos entre 1 y 5 micras son considerados como núcleos del floc, lo ideal es que las partículas tengan menor a una micra de diámetro.
- **Influencia de sales disueltas:** la presencia de sustancias disueltas insolubles en el medio causará modificaciones en el pH, tiempo requerido para la floculación y requerirá el uso de una mayor cantidad de coagulante.

#### **2.4. Coagulantes químicos**

“Los principales coagulantes utilizados para desestabilizar las partículas y producir el floc son: sulfato de aluminio, aluminato de sodio, cloruro de aluminio, poli cloruro de aluminio, cloruro férrico, sulfato férrico, sulfato ferroso, polielectrolitos” (Cordero, 2014) .

Los coagulantes químicos como los policloruros de aluminio (PAC's), clorhidrato de aluminio (ACH) y polisulfatos de aluminio son los más utilizados para el tratamiento de aguas residuales, debido a su rendimiento, disponibilidad, costo y efectividad (Shak & Wu, 2014).

“En la última década también han presentado gran aplicación las sales hidrolizadas de estos metales, siendo los conocidos PAC (Policloruro de Aluminio) y PAS (Poli sulfato de Aluminio), los mismos no tienen que ser confundidos con los polímeros, que son empleados como ayudantes de coagulación, ya que los primeros están definidos por

formulas químicas que abarcan gran cantidad de compuestos con características y propiedades únicas que dan la fiabilidad a los PAC's para desenvolverse con un excelente rendimiento” (Comisión Nacional del Agua, 2007).

## **2.5. Cloruro férrico.**

El cloruro férrico de formula ( $\text{FeCl}_3$ ) es usado como coagulante, tiene ventajas al compararlo con otros, entre las que se destacan su efectividad en amplios rangos de pH y temperatura. Además, genera iones trivalentes de mayor peso molecular, esenciales para el proceso de coagulación (Zerbatto et al., 2009).

Se ha comprobado que la dosis de cloruro férrico es más baja que la de la alúmina para obtener los mismos resultados. Debido a todas estas ventajas, el cloruro férrico ha sido incorporado en el tratamiento de potabilización de aguas en un gran número de plantas de América y Europa (Zerbatto et al., 2009).

### **2.5.1. Aplicaciones del cloruro férrico.**

El cloruro férrico es un sólido de color naranja a marrón-negro, es ligeramente soluble en agua y es incombustible. Cuando el cloruro férrico se encuentra húmedo es corrosivo para el aluminio y la mayoría de los metales y se utiliza en procedimientos como:

- **Aguas residuales:** se utiliza en la eliminación de metales pesados en plantas de tratamiento de agua residual y clarifica el agua haciendo precipitar los sólidos.
- **Agua potable:** El cloruro férrico ayuda a clarificar el agua potable ya que es un coagulante y hace que los sólidos en suspensión sedimenten, ya que por el tamaño demandarán un tiempo largo para sedimentar.

## **2.6. Coagulantes naturales**

Los coagulantes naturales son una gran alternativa en comparación con los coagulantes químicos, los cuales se producen de manera espontánea por reacciones bioquímicas que ocurren normalmente en animales y plantas. Algo importante es que muestran cero o mínima toxicidad y muchos de ellos presentan proteínas solubles en agua (Guzmán, Villabona, Tejada, & García, 2013).

“Algunos de ellos tienen propiedades coagulantes o floculantes que actúan de modo similar a los coagulantes sintéticos, aglomerando las partículas en suspensión que

contiene el agua cruda, facilitando su sedimentación y reduciendo la turbidez; en muchos lugares son utilizados en forma empírica por nativos para aclarar el agua turbia, con muy buenos resultados” (Guzmán et al., 2013).

Los biopolímeros naturales como el almidón y la celulosa, han sido investigados como una iniciativa en los procesos de coagulación-floculación para realizar la clarificación en aguas turbias y tienen una gran peculiaridad que estos polímeros son biodegradables.

### **2.6.1. Tipos de biopolímeros naturales.**

Según (Cuadro & Rodas, 2017) detallan los tipos de biopolímeros naturales como:

- **Biopolímeros catiónicos:** Estos biopolímeros tienen una carga positiva y son denominados polímeros de electrolitos fuerte.
- **Biopolímeros aniónicos:** Estos biopolímeros tienen en su forma grupos ácidos del ácido carboxílico.
- **Biopolímeros no-iónicos:** En este grupo se encuentran los almidones, derivados de la celulosa, gomas y gelatinas. Son empleados como floculantes y varían en su peso molecular y estructura, teniendo la ventaja de que con biodegradables (Cabera & Ramirez, 2014).

### **2.7. Almidón de yuca.**

El almidón es uno de los polímeros naturales más importante que existe y es la mayor fuente de energía obtenida de diversas plantas. Se encuentra en las semillas de cereales (maíz, trigo, arroz, sorgo), en tubérculos (papa), en raíces (yuca, batata, arrurruz), en semillas de leguminosas (frijoles, lentejas, guisantes), frutas (bananas y manzanas y tomates verdes), troncos (palma sago) y hojas (tabaco) (FAO, 2007).

“Las raíces tuberosas de la yuca tienen altas reservas de almidón depositados como gránulos en la corteza, pulpa y semillas. El almidón es una mezcla de dos sustancias: la amilosa y la amilopectina. Dichas macromoléculas se diferencian por su estructura y sus concentraciones son las que definen las propiedades y características del almidón” (Moreira, 2017).

“El almidón de yuca es un polímero en el que los monómeros se encuentran unidos por enlaces 1-4 y, ocasionalmente, se ramifican, formando un enlace adicional en posición 1-6. Es la forma principal en la que se almacena el carbohidrato en los tejidos de la mayoría de las especies vegetales superiores y se acumula en las hojas de las plantas

y en tejidos no fotosintéticos, especialmente, los implicados en la reproducción, tales como semillas, frutos y tubérculos” (Castro, 2016).

El almidón, además de ser consumido , se puede someter a una variedad de procedimientos para la transformación en donde cambian sus propiedades funcionales y lo convierten en estabilizante, emulgente y gelificante (Castro, 2016).

### **2.7.1. Componentes del almidón.**

“El almidón está constituido por unidades de glucosa dispuestas en dos componentes: amilosa y amilopectina; su proporción varía de un tipo a otro según sea su fuente. Estas macromoléculas se caracterizan por su grado de polimerización o ramificación lo cual afecta su comportamiento frente a los procesos de degradación” (FAO, 2007).

Para un mejor entendimiento se detallan los 2 componentes del almidón que hacen de este un importante polímero.

### **2.7.2. Amilosa.**

“La amilosa es un polímero fundamentalmente lineal, se encuentra constituido por 250-300 unidades de D-glucosa donde predomina el enlace  $\alpha$ -(1→4). Aunque hay moléculas que pueden tener ramificaciones  $\alpha$ -(1→4). La amilosa al entrar en contacto con el agua se disuelve y adquiere una estructura secundaria helicoidal, donde comprende 6 unidades de glucosa en cada vuelta de hélice. La fórmula molecular de la amilosa es  $(C_6H_{10}O_5)_nH_2O$ . La estructura lineal de la amilosa permite la formación de complejos de inclusión con alcoholes, yodo” (Brumovsky, 2014).

### **2.7.3. Amilopectina.**

“La amilopectina es el componente que más predomina en el almidón, se encuentra en un porcentaje del 70 al 80% dependiendo de la fuente de almidón, en casos especiales como almidones cerosos alcanza un porcentaje del 98% y 99%. La estructura, proporción además de la composición afectan a las propiedades del almidón. La Amilopectina se encuentra estructurada por cadenas de  $\alpha$ -(1→4), en cambio en los puntos de ramificación se encuentran enlaces  $\alpha$ -(1→6) estos ocupan un porcentaje del 5% al 6% del total de enlaces. La amilopectina posee un peso molecular de  $1 \times 10^6$  variando hasta  $1 \times 10^8$  Da, según la fuente del almidón, el método de determinación del peso molecular y el fraccionamiento de las moléculas de amilopectina y amilosa” (Espinosa, 2008).

## **2.8. Máquinas de aprendizaje**

Las máquinas de aprendizaje son modelos computacionales los cuales se cimentan a partir del mismo principio de comportamiento y características de una neurona biológica (Izuareta, 2011).

Las máquinas de aprendizaje están conformadas por modelos matemáticos que están basados en algoritmos de cálculo utilizando nodos de interconexión y una serie de conexiones entre estas organizándose por niveles o capas (Sprockela, Diaztagleb, Alzatec, & González, 2014).

### **2.8.1. Diseño.**

“El diseño de una red se basa en modelar matemáticamente el problema en cuestión y formular una solución por medio de un algoritmo codificado que tenga una serie de propiedades que permitan resolver el problema. El objetivo del diseño de la red es conseguir que la red aprenda automáticamente las propiedades deseadas, para ello es importante establecer el tipo de modelo de red a utilizar, las variables a incorporar y el procesamiento de la información que formará el conjunto de entrenamiento” (Izuareta, 2011).

### **2.8.2. Entrenamiento.**

“El aprendizaje consiste en entrenar la red a partir de un conjunto de datos o patrones de entrenamiento de entrada y salida. El objetivo del proceso de entrenamiento de la red es ajustar los “pesos” de la red de manera tal que la salida generada por la red sea lo más cercano a los valores reales de salida de cada entrada, es decir, la red trata de encontrar un modelo al proceso desconocido que genere la respuesta de salida. Las máquinas de aprendizaje tienen la necesidad de ser previamente entrenadas, mostrándoles en su capa de entrada unos ejemplos y ella misma se ajusta en función de alguna regla de aprendizaje” (Tablada, 2010).

## **2.9. Algoritmos de Machine Learning**

Machine Learning es un subcampo de las ciencias de la computación y una rama de la inteligencia artificial cuyo objetivo es desarrollar técnicas que permitan a los computadores aprender, es decir, generalizar comportamientos y conocimientos a partir de una información suministrada en forma de ejemplos (Brett, 2015).

## **2.10. Algoritmos para las máquinas de aprendizaje**

El aprendizaje de modelos computacionales se da a través de un algoritmo de aprendizaje supervisado o no supervisado, las máquinas de aprendizaje ajustan su arquitectura y parámetros de manera de poder minimizar alguna función de error que indique el grado de ajuste a los datos y la capacidad de generalización de las redes (Salas, 2004).

### **2.10.1. Aprendizaje supervisado.**

El aprendizaje supervisado estudia la construcción de sistemas capaces de aprender a partir de datos, incluye una variedad de sistemas, desde sistemas de visión por ordenador hasta sistemas para detectar correo no deseado. En todos los casos, un sistema que aprende debe ser capaz de generalizar, es decir, de encontrar patrones y regularidades en los datos que le permitan desempeñarse bien en datos que no ha observado previamente (Elsevier, 2016).

En este caso, los datos disponen de atributos adicionales que son los que se intentan predecir, pues aquí sobresalen los algoritmos de clasificación donde las muestras se etiquetan como pertenecientes a dos o más clases (Utrera, 2017) .

### **2.10.2. Aprendizaje no supervisado.**

El aprendizaje no supervisado se presenta sólo un conjunto de patrones de las máquinas de aprendizaje, y el objetivo del algoritmo de aprendizaje es ajustar los pesos de la red de manera tal que la red encuentre alguna estructura o configuración presente en los datos. Los datos de entrenamiento consisten en un conjunto de vectores de entrada sin ningún valor o etiqueta (Salas, 2004).

## **2.11. Selección de algoritmos lineales**

### **2.11.1. Algoritmo de Regresión Lineal (LR).**

La regresión logística es un método lineal que se utiliza para clasificación, realiza un tipo de análisis utilizado para predecir resultados de una variable categórica en función de variables independientes o predictoras. Muy útil para modelar las probabilidades de un evento ocurriendo como función de otros factores (Utrera, 2017).

### **2.11.2. Algoritmo de Regresión Lineal Generalizado (GLM).**

Es una forma de regresión. Busca una relación estadística entre una variable de respuesta y variables predictoras por medio de una función de enlace. Permite trabajar

con distribuciones de distinta naturaleza, así como con datos no lineales y no constantes (Martínez-meyer, 2016).

### **2.11.3. Algoritmo de Regresión Lineal Penalizada (GLMNET).**

El algoritmo *Penalized Linear Regression*, es un paquete del programa R Studio que realiza procedimientos extremadamente eficientes para el montaje de toda la regularización para la regresión lineal, regresión logística y los modelos multinomiales, la principal función de este algoritmo se basa en ajustar los modelos lineales a través de la máxima verosimilitud penalizada (Carrasco, 2016) .

Este algoritmo detalla el proceso de enlace que se realiza a través de la penalización de la magnitud y el número de coeficientes del modelo final de regresión, de esta forma se evita el problema del sobre ajuste. Este tipo de algoritmo es evaluado como efectivo en conjuntos de datos con muchas variables predictoras y pocas observaciones individuales (Fontalvo, De la HOZ, & Olivos, 2019).

## **2.12. Selección de algoritmos no lineales**

### **2.12.1. Algoritmo K Nearest Neighbors (K-NN).**

“Este algoritmo de aprendizaje supervisado, clasifica cada dato nuevo en el grupo que corresponda. Es decir, calcula la distancia del elemento nuevo a cada uno de los existentes, y ordena dichas distancias de menor a mayor para ir seleccionando el grupo al que pertenecer. Este grupo será, por tanto, el de mayor frecuencia con menores distancias. Esto quiere decir que a partir de un juego de datos inicial su objetivo será el de clasificar correctamente todas las instancias nuevas. El juego de datos típico de este tipo de algoritmos está formado por varios atributos descriptivos y un solo atributo objetivo” (Gonzalez, 2017).

### **2.12.2. Algoritmo Support Vector Machines (SVM).**

“Este algoritmo de aprendizaje supervisado, constituye un método basado en aprendizaje para la resolución de problemas de clasificación y regresión. En ambos casos, esta resolución se basa en una primera fase de entrenamiento (donde se les informa con múltiples ejemplos ya resueltos, en forma de pares {problema, solución}) y una segunda fase de uso para la resolución de problemas, el SVM se convierten en una caja negra que proporciona una respuesta (salida) a un problema dado (entrada)” (Alvarez, 2016).

### 2.12.3. Algoritmo Classification and Regression Trees (CART).

Son un tipo de algoritmos de aprendizaje supervisado en donde existe una variable predefinida, principalmente usados en problemas de clasificación. Las variables de entrada y salida pueden ser categóricas o continuas así estas dividen el espacio de predictores (variables independientes) en regiones distintas y no sobrepuestas. Se divide la población o muestra en conjuntos homogéneos basados en la variable de entrada más significativa (Mendoza, 2018).

### 2.13. Métricas de regresión

- **RSME:** El error cuadrático medio, mide la cantidad de error que hay entre dos conjuntos de datos, compara un valor predicho y un valor observado o conocido (Cabrera, 2011).
- **MAE:** El error absoluto medio o MAE es un puntaje lineal, lo que significa que todas las diferencias individuales se ponderan por igual en el promedio. Por ejemplo, la diferencia entre 10 y 0 será el doble de la diferencia entre 5 y 0 (González L, 2018).
- **Rsquared:** Indica la bondad o la aptitud del modelo, a menudo se utiliza con fines descriptivos y muestra que también las variables independientes seleccionadas explican la variabilidad en sus variables dependiente (González L, 2018).

### 2.14. Optimización

“El proceso de optimización consiste en la determinación de los valores de cada una de las variables que intervienen en un sistema, con los cuales se obtendrán los mejores resultados posibles o un mínimo posible de la variable respuesta de un sistema determinado, es decir que de un conjunto de resultados probables, que son una respuesta adecuada frente a una situación determinada, se seleccionará como la alternativa indicada aquella con la que se consiga una gestión adecuada de los recursos que intervienen en el proceso y así mismo de la capacidad de respuesta” (Castrillon & Giraldo, 2012).

## CAPÍTULO III

### 3. MATERIALES Y METODOS

#### 3.1. Zona de estudio

El Relleno Sanitario de Pichacay está situado en la parroquia Santa Ana, localidad de Pichacay a 21 km de la ciudad de Cuenca, desde el año 2001, la Empresa Pública Municipal de Aseo de Cuenca, EMAC EP está a cargo de la recolección de los desechos y residuos sólidos del Cantón Azuay y gestiona el "Complejo de Desarrollo Humano y Ambiental Pichacay".

El relleno presenta todas las características de seguridad ambiental, contando este con la impermeabilización del fondo con arcilla y geomembrana y de un sistema de captación de lixiviado de 73 m<sup>3</sup> por día aproximadamente, en algunos casos los lixiviados son trasladados a las instalaciones de la Planta de Tratamiento de Aguas Residuales operada por ETAPA y ubicada a 6 km de la Ciudad (Mejía & Pinos, 2012).

En el relleno sanitario Pichacay cuentan con piscinas de almacenamiento del lixiviados, en donde se les da un tratamiento con bacterias, las cuales ayudan a la degradación de la materia orgánica minorando la carga contaminante de este líquido.

El Relleno Sanitario de Pichacay se encuentra estructurado por dos sistemas:

- **NORTE 1:** consta con 9 terrazas de 5 metros de altura cada una y en la actualidad ya está completamente llena, esto en un lapso de 10 años. Cada terraza consta de tubos de drenes de lixiviados que desembocan directamente en canales, mismos que fluyen a la laguna 1 de lixiviados.
- **NORTE 2:** se encuentra en pleno proceso de relleno, a diferencia del Sistema Norte 1, además, de los drenes de lixiviados consta con unos canales extras en caso de taponamiento, los lixiviados de este sistema desembocan en la laguna de lixiviados 2.



**Figura 2. Ubicación del Relleno Sanitario "Pichacay".**

Fuente: *Google Maps*

### **3.2. Toma de muestras**

El tipo de muestra analizada fue de tipo simple, la toma se realizó en el Relleno Sanitario de Pichacay; se tomaron directamente las muestras en la fase NORTE 2 donde se está en pleno proceso de relleno, el lixiviado que es generado en las celdas pasa por medio de una tubería, llegando a un solo punto de recolección antes de llegar a la piscina, la cual es de fácil acceso, ya que aquí diariamente se mide el caudal del lixiviado, y posteriormente los técnicos den el correcto tratamiento en la piscina.

### **3.3. Sistema de toma de muestras**

Los envases utilizados fueron tres de plásticos de 24 litros cada uno, los cuales fueron lavados previamente antes de la recolectar la muestra, los recipientes fueron llenados en su totalidad para luego ser sellados, transportados y guardados en un lugar seguro dentro del laboratorio del Centro de Investigación, Innovación y Transferencia de Tecnología, CIIT de la Universidad Católica de Cuenca. Esto se realizó con la ayuda de 2 trabajadores de la EMAC EP, con las precauciones de seguridad que el caso amerita.



**Figura 3. Toma de muestras dentro del relleno.**

Fuente: Autoría propia

### **3.4. Parámetros fisicoquímicos que intervienen en la coagulación – floculación**

Con respecto a los antecedentes encontrados al momento de monitorear los diferentes parámetros que intervienen el proceso de coagulación-floculación, se determinó ciertos parámetros fisicoquímicos que influyen en la eficiencia del proceso en cuestión.

Los parámetros fueron seleccionados con el fin de monitorear la eficiencia del proceso de coagulación-floculación realizado por medio del Ensayo de jarras o Jar Test y así mismo para ser utilizados como variables de entrada para el modelo de las máquinas de aprendizaje.

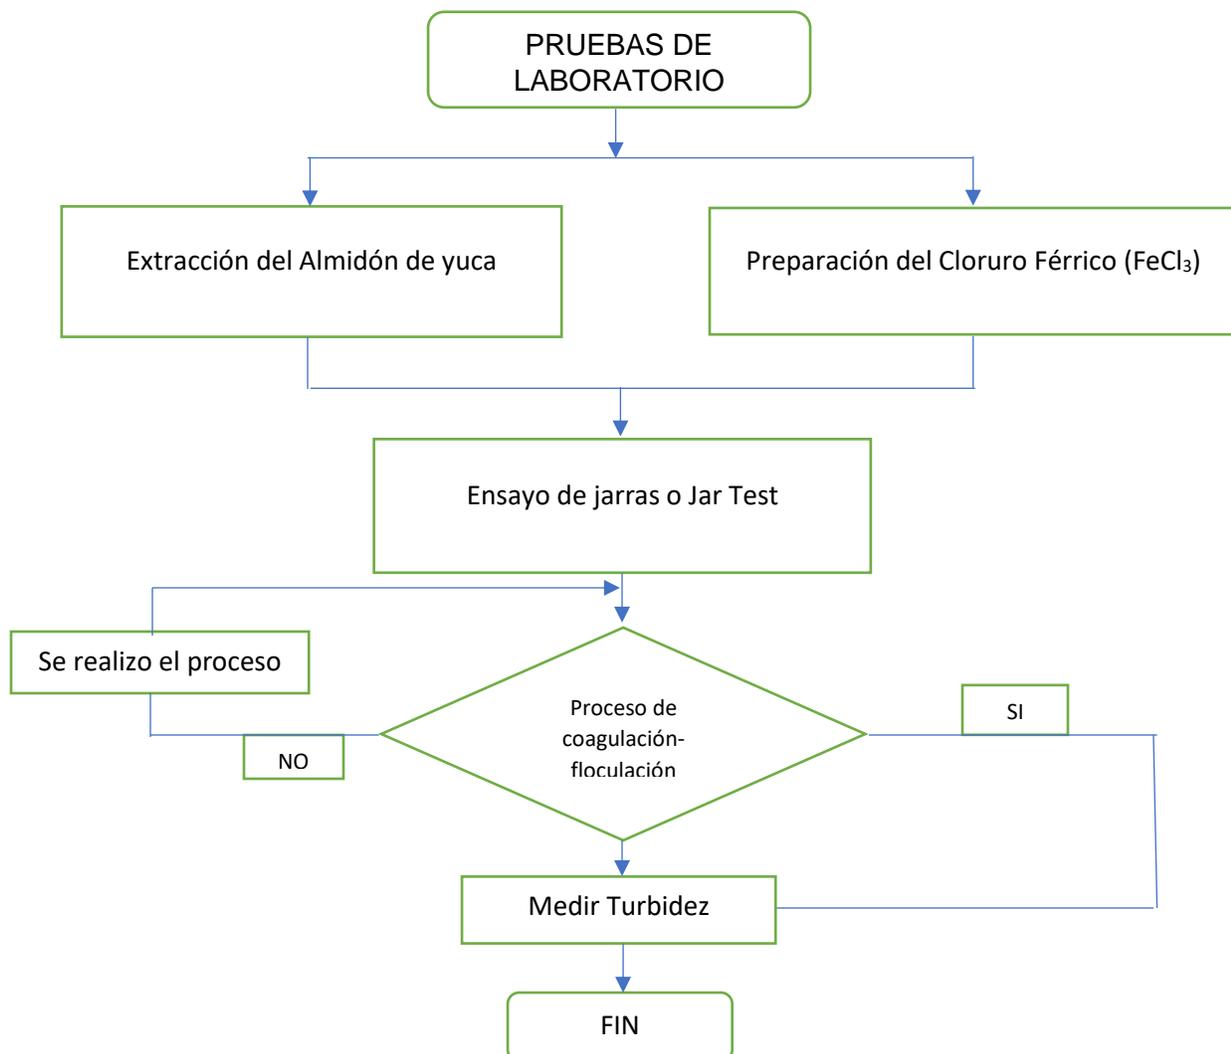
- **Turbidez:** Este parámetro se establece como el principal en cuanto a la efectividad del proceso de coagulación-floculación, ya que las partículas que forman la turbidez establecen una parte sustancial del nivel de contaminación en el agua que se trata.
- **pH:** Para cada coagulante existe un rango óptimo de pH, en la cual una buena floculación ocurre en un periodo de tiempo más corto y con la misma dosis de coagulante (Osorno, 2009).
- **Color:** El color se seleccionó debido a que suele estar relacionado con la turbidez ya que las partículas coloidales cargadas negativamente aportan color al agua y

adicionalmente su remoción puede lograrse por medio de un agente coagulante (Castaño, 2011).

- **Conductividad:** La conductividad se establece como parámetro a tener en cuenta ya que es una medida indirecta de la cantidad de iones en solución presentes en el agua, en general sólidos disueltos que afectan la calidad del fluido (Martel, 2010).
- **Temperatura:** La temperatura tiende a influir en el proceso de coagulación ya que a una menor temperatura es mayor el tiempo que se necesita para que exista una floculación de las partículas suspendidas en el agua (Castrillon & Giraldo, 2012).

### 3.5. Pruebas de laboratorio

Las pruebas de laboratorio se llevaron a cabo en el CIITT, que cuenta con la tecnología necesaria para la realización del trabajo.



### **3.5.1. Obtención del almidón de yuca.**

El método de extracción o de la obtención del almidón es el método utilizado por (Bernado & Hernan, 2002)

**Recepción de las raíces:** las raíces una vez cosechadas deben ser transportadas a la planta de procesamiento dentro de las siguientes 24-48 horas para evitar su deterioro fisiológico y/o microbiano. Un factor importante en la producción de almidón de yuca de alta calidad, es que todo el proceso desde la cosecha de las raíces hasta el secado del almidón sea ejecutado en el más corto tiempo posible.

**Lavado y pelado de las raíces:** en esta etapa se elimina la tierra y las impurezas adheridas a las raíces. La cascarilla se desprende por la fricción de unas raíces con otras durante el proceso de lavado. Normalmente, las pérdidas en el lavado son de 2-3 por ciento del peso de las raíces frescas. Se debe evitar pérdida de la cáscara ya que esta también contiene almidón.

**Rallado o desintegración:** en esta etapa se liberan los gránulos de almidón contenidos en las células de las raíces de la yuca. La eficiencia de esta operación determina, en gran parte, el rendimiento total del almidón en el proceso de extracción. Si el rallado no es eficiente, no se logran separar totalmente los gránulos de almidón de las fibras; el rendimiento del proceso es bajo y se pierde mucho almidón en el afrecho desechado. Por otra parte, si el rallado es demasiado fino, los gránulos muy pequeños de almidón sufren daño físico y más tarde deterioro enzimático

**Colado o extracción:** en esta etapa se realiza la separación de la pulpa o material fibroso de la lechada de almidón. Se debe evitar que pequeñas partículas de fibra pasen a la lechada de almidón; es por ello que en muchos casos se recomienda realizar un recolado de la lechada con el objeto de retener las fibras finas que pudieron pasar a la lechada.

**Sedimentación o deshidratación:** se realiza por medio de sedimentación o centrifugación, para separar los gránulos de almidón de su suspensión en agua.

**Secado:** puede ser realizado dependiendo del nivel tecnológico por secado solar o artificial. En ambos casos, se busca remover la humedad del almidón hasta un 12 o 13 por ciento.

**Acondicionamiento:** comprende las etapas de molienda, tamizado y empaque.

### 3.5.2. Preparación del cloruro férrico.

El cloruro férrico que se uso fue de presentación sólida, por lo que se hizo necesaria la preparación.

Se pesaron 85.84 g de  $\text{Fe Cl}_3$  en la balanza analítica y se mezclaron con 1000 ml de agua destilada en un balón aforado de este mismo volumen, con el fin de lograr su disolución se agitó hasta obtener una mezcla homogénea.



**Figura 4. Preparación del cloruro férrico**

Fuente: Autoría propia

### 3.5.3. Ensayo de jarras.

“Consiste en un arreglo de vasos de precipitados en los que a un volumen constante de agua se agregan diferentes dosis de coagulante (que representan una concentración específica del agente coagulante) y se ejecutan las mezclas rápida y lenta por medio de un conjunto de paletas que componen el agitador múltiple, con las que se consiguen condiciones hidráulicas similares en todas las muestras” (Osorno, 2009).

“A cada uno de los vasos se le agrega una dosis con una concentración de coagulante determinada, que puede variar 0.5 mg/L entre vaso y vaso, posterior a esto se agitan las muestras a una velocidad de 70 rpm durante un minuto generalmente, para simular la mezcla rápida. Pasado este tiempo, se procede a simular la mezcla lenta, donde se disminuye la velocidad a un rango de 30 rpm por un lapso de 15 minutos, luego se deja sedimentar durante un tiempo de 20 minutos. Es importante tener en cuenta que estas condiciones pueden presentar variaciones de acuerdo al tipo de agua y coagulante con que se esté llevando a cabo el proceso” (Castrillon & Giraldo, 2012).

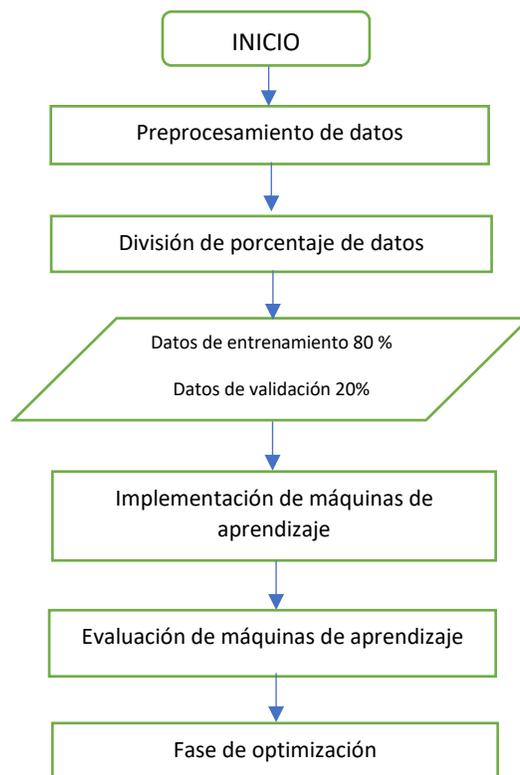


**Figura 5. Jar Test (Ensayo de Jarras).**

Fuente: Autoría propia

### 3.6. Metodología de aplicación de máquinas de aprendizaje

El diagrama que se presenta a continuación, hace referencia a los procesos que se llevaron a cabo para la implementación y programación de la máquina de aprendizaje para la predicción de datos.





1. Mediante la programación, se realiza un preprocesamiento de datos, carga las diferentes librerías necesarias para la ejecución del código. Se utiliza la función `read_excel` para que los datos que se tienen en Excel fueran leídos y transformados al programa.

```

#Librerías necesarias para la RNA
library(mlbench)
library(lattice)
library(ggplot2)
library(caret)
library(corrplot)
library(readxl)

#Cargar el conjunto de datos de Pruebas
dosis<- read_excel("C:/Users/DELL/Desktop/TABLA_RESULTADOS.xlsx")
  
```

**Código 1.** Cargar el conjunto de datos de Prueba.

2. La selección de variables nos permite crear una matriz de correlación, para saber cuáles son las relaciones que tienen las variables de ingreso a la red.

```

set.seed(20)
cutoff <- 0.70
correlaciones <- cor(dataset[,2:61])
altaCorrelacion <- findCorrelation(correlaciones, cutoff = cutoff)
for(value in altaCorrelacion){print(names(dataset)[value])}
  
```

**Código 2.** Correlaciones entre variables.

3. Lo siguiente es la validación del conjunto de datos utilizado para confirmar la precisión del modelo final, se destina un porcentaje para datos de entrenamiento y de validación.

```

#División de los datos para el 80% de entrenamiento
set.seed(20)
validationIndex <- createDataPartition(dosis$CLORURO, p=0.8, list = FALSE)
  
```

```

#Seleccionar el 20% de validación
validation <- dosis[-validationIndex,1]
#Usar del 80% restante para entrenamiento / validación de modelo
dataset <- dosis[validationIndex,1]

```

**Código 3.** División de datos.

4. Para una mejor evaluación del conjunto de datos se utiliza la función `trainControl`, la cual permitirá una evaluación de los algoritmos lineales y no lineales de regresión. entre ellos los algoritmos lineales “LR”, “GML”, “GMLNET” y los algoritmos no lineales “CART”, “SVM”, “K-NN”.

```

#Establecer una 10-fold con 3 repeticiones
trainControl <- trainControl(method = "repeatedcv", number = 10, repeats = 3)
metric <- "RMSE"
dataset2 <- dataset[, -21]
validation2 <- validation[, -21]
#ALGORITMOS LINEALES
#LM-- linear regression
set.seed(20)
fit.lm2 <- train(CLORURO~, data = dataset2, method = "lm", metric= metric, preProc= c("center","scale"),
trControl = trainControl)
#GLM-- generalized linear regression
set.seed(20)
fit.glm2 <- train(CLORURO~, data = dataset2, method = "glm", metric= metric, preProc= c("center","scale"),
trControl = trainControl)
#GLMnet-- penalized linear regression
set.seed(20)
fit.glmnet2 <- train(CLORURO~, data = dataset2, method = "glmnet", metric= metric, preProc=
c("center","scale"), trControl = trainControl)
#ALGORITMOS NO LINEALES
#SVM-- support vector machines
set.seed(20)
fit.svm2 <- train(CLORURO~, data = dataset2, method = "svmRadial", metric = metric, preProc = c("center",
"scale","BoxCox"), trControl = trainControl)
#CART--classification and regression trees
set.seed(20)
grid2 <- expand.grid(cp = c(0, 0.05, 0.1))
fit.cart2 <- train(CLORURO~, data = dataset2, method = "rpart", metric= metric, tuneGrid = grid2,
preProc= c("center","scale"), trControl = trainControl)
#KNN-- k nearest neighbors

```

```
set.seed(20)
fit.knn2 <- train(CLORURO~., data = dataset2, method = "knn", metric= metric, preProc=
c("center","scale"), trControl = trainControl)
```

**Código 4.** *Algoritmos lineales y no lineales.*

5. Se evaluarán los algoritmos utilizando las métricas de regresión como MAE, RMSE y Rsquared. Se calcula los errores entre los datos observados y datos simulados para evaluar el comportamiento de la máquina de aprendizaje.
6. Fase de optimización, mejoramiento del modelo y disminución de errores para mejor ajuste.
7. Forecasting o presentación de la máquina de aprendizaje que mejor se acopla y se ajusta a la predicción de datos.

## **CAPÍTULO IV**

### **4. RESULTADOS Y DISCUSIÓN**

#### **4.1. Extracción del almidón de yuca**

Al momento de separar el almidón sedimentado de la lechada se probaron tres métodos los cuales fueron: decantación, filtración al vacío y centrifugación. El primero es el más eficiente ya que se obtiene la mayor cantidad de producto, para la recuperación del almidón que seguía en suspensión dentro del agua que se separó por decantación se pasó por un proceso de centrifugación a 1000 rpm por 25 minutos. La filtración al vacío no dio buenos resultados porque los gránulos de almidón no se quedaban retenidos en el papel filtro (Desiderio, 2017).

En la experimentación, la extracción del almidón se realizó mediante la decantación en los vasos de precipitados, fue el mejor procedimiento que logra sacar o tener más almidón de yuca, es un proceso más demorado, pero más eficiente, ya que se tiene pocas perdidas del almidón en la lechada al momento de sacarlo del vaso para llevarlos a la estufa, el líquido de color blanco se debe poner a desecar en la estufa para obtener el almidón de forma sólida y proceder al molerlo y se obtiene el biopolímero que será utilizado en el tratamiento del lixiviado.

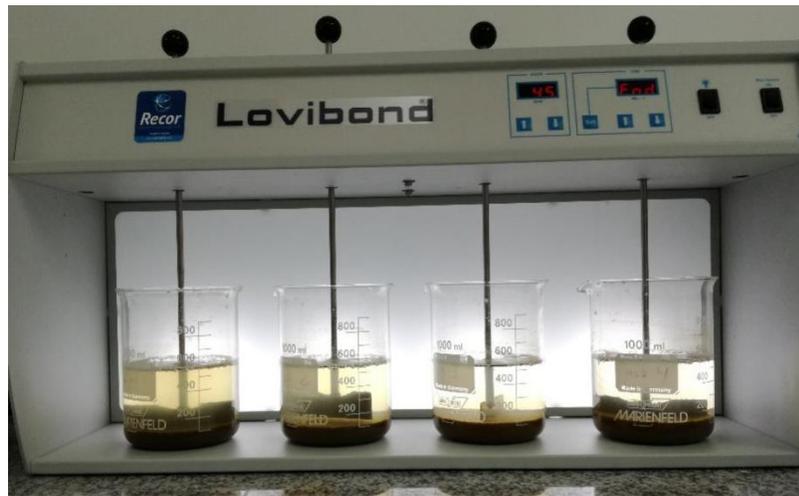
#### **4.2. Prueba de jarras**

En la experimentación para la determinación de la dosis optima del coagulante (almidón de yuca) y floculante ( cloruro férrico ) se realizó con la metodología de las 2 autoras mencionadas anteriormente pero modificando las revoluciones por minutos, en vasos de 500 ml con lixiviado se procede a realizar el Jar Test o prueba de jarras, primero se adiciona el floculante en diferentes concentraciones que van desde 0.5 ml a 300 revoluciones por un minuto, después se baja las revoluciones a 45 por 25 minutos y se adiciona el coagulante en diferentes concentraciones que van desde 0.5 ml y se deja sedimentar por 20 minutos y se procede a realizar las mediciones turbidez.

Se aumentaron las revoluciones en la experimentación porque a mayor, movimiento en los vasos con el agua, mayor colisión de partículas se unen mejor y más grandes se hacen los flóculos y coagula mejor.

En las primeras experimentaciones en los ensayos de jarros se obtuvieron mediciones de turbidez de 36 NTU y en función de repeticiones y más ensayos se logró obtener

mediciones de turbidez de hasta 3 NTU siendo este el valor más aceptable en todo el proceso.



**Figura 6. Prueba de jarras adicionando biopolímeros.**

Fuente: Autoría propia

### **4.3. Resultados de la medición de turbidez, solidos, pH**

Según los autores (Orduz & Portilla, 2017) recomiendan trabajar con 2 tipos de coagulantes como lo son el cloruro férrico ( $\text{FeCl}_3$ ) y sulfato de aluminio tipo b ( $\text{Al}_2(\text{SO}_4)_3$ ), en la experimentación realizada de estos autores con aguas de planta de tratamiento de agua potable, detallan que la utilización de cloruro férrico disminuye los valores de turbidez y una remoción de casi el 90 %, se debe tomar en cuenta que el lixiviado es un líquido más complicado de tratar, pero con este trabajo se comprueba que el cloruro férrico es un gran coagulante ofreciendo mejores resultados de remoción de turbidez, sedimentación de flocs.

#### **4.3.1. Turbidez.**

Los resultados obtenidos de las mediciones de turbidez, las cuales se fueron midiendo antes y nuevamente al finalizar cada ensayo de jarras, esta variable presenta un gran cambio o comportamiento, pues este parámetro es el de mayor importancia el cual detalla que tan efectiva fue la remoción de solidos al aplicar tanto el almidón de yuca como el cloruro férrico. Para poder verificar la remoción de solidos se procedió a realizar la medición de la muestra en el turbidímetro.

La medición de turbidez inicial y final presentan cambios no lineales, esto quiere decir que no presentan un comportamiento uniforme, pues se contó con turbiedades iniciales de 1000 NTU que es el mayor valor que lee el turbidímetro y el menor valor de turbidez que se obtuvo fue de 2,39 NTU, por medio de los porcentajes de remoción se puede tener una idea de cuan efectivo es el proceso que se realizó, a continuación se pondrá unos ejemplos de los porcentajes de remoción en la experimentación de lixiviados.

Donde (Ti) es la turbidez inicial y (Tf) la turbidez final:

$$\text{Porc. Remocion}\% = \frac{T_i - T_f}{T_i} * 100 \quad (1)$$

**Tabla 1. Porcentaje de remoción.**

<u>Turbidez Inicial (NTU)</u>	<u>Turbidez final (NTU)</u>	<u>Porc. Remoción %</u>	<u>Dosificación Cloruro</u>
300	212	29,33	0,5
300	161	46,33	1
300	35,2	88,26	3
300	28,4	90,53	5
300	5,05	98,31	7
300	2,96	99,01	9
300	5,71	98,09	11
300	28,4	90,53	13

**Fuente:** Autoría propia

El resultado de este cálculo demostró que para el menor nivel de dosificación de cloruro (0,5 ml) se consiguió un porcentaje de remoción (29.33%), mientras que para un mayor nivel de dosificación (9 ml) se obtuvo el mayor porcentaje de remoción (99.01%), lo cual demuestra que existe una relación directamente proporcional entre la dosificación del cloruro y la turbidez final en este caso el porcentaje de remoción, ya que a mayor dosificación de cloruro más alto es el porcentaje de remoción en ciertos casos.

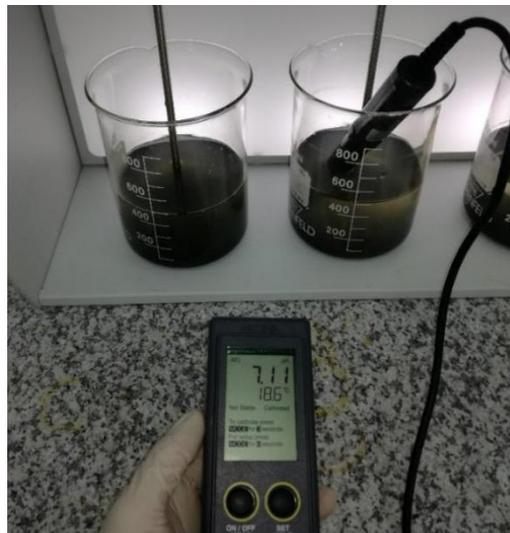


**Figura 7. Medición de turbidez (Turbidímetro).**

Fuente: Autoría propia

#### 4.3.2. El pH.

En este caso el pH no es un factor que incida en los ensayos ya que el cloruro férrico puede actuar de una manera sin alterar el ensayo, no tiene un límite mínimo o máximo en el rango de pH, los valores de pH varían entre rangos de 7,05 hasta 5,09, de esta forma el pH cambia en función de cuanto cloruro se haya adicionado en el ensayo variando el rango en poca cantidad.



**Figura 8. Medición de pH (pH-metro).**

Fuente: Autoría propia

#### **4.3.3. Sólidos.**

El lixiviado del relleno sanitario es un líquido que percola a través de los residuos depositados y que arrastra sólidos disueltos o suspendidos y materiales a partir de ellos. El lixiviado está conformado por la mezcla de las aguas lluvias y otros productos que proceden de los procesos de degradación de los residuos.

Para este caso los lixiviados han tenido gran cantidad de sólidos y esta es la causa del color tan oscuro que tiene, pero algo que se debe tener en cuenta es que dentro del vertedero no sedimentan fácilmente, como con el proceso que se lleva a cabo con los biopolímeros.



**Figura 9. Sólidos suspendidos (Desecador).**

**Fuente:** Autoría propia

#### **4.4. Resultados afines de la dosis óptima de coagulante**

En todo el proceso de la realización de los ensayos de laboratorio, el lixiviado generó inconvenientes para determinar la dosis óptima de almidón de yuca y del cloruro férrico.

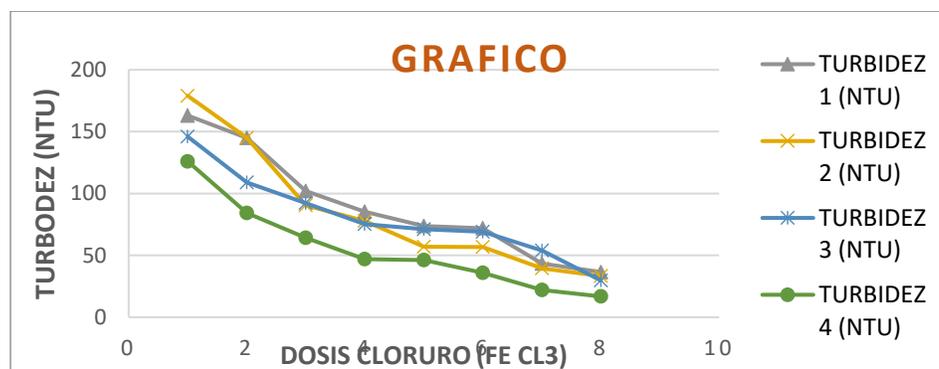
Al realizar los ensayos de jarras para determinar la dosis de almidón correcta, se varió en amplio rango de mililitros el almidón para que este haga efecto en el lixiviado, este era el punto de partida de la experimentación. Después de muchos intentos y repeticiones con mililitros del almidón se determinó en una cierta cantidad de 5 mililitros que en los ensayos de laboratorio era la dosis óptima para este tipo de líquido.

Como punto de partida, se debe evaluar el cloruro férrico ( $\text{FeCl}_3$ ) en función de la dosis ya obtenida de almidón para así obtener las diferentes dosis de cloruro, en los vasos del ensayo de jarras se adiciono diferentes dosis de cloruro férrico que van desde los 0,1 a 22 mililitros para analizar la efectividad del mismo en los ensayos de cada prueba realizada.

**Tabla 2. Ensayos de turbidez en función del cloruro (de 8 a 22 ml).**

<u>Cloruro (ml)</u>	<u>Turbidez 1 (NTU)</u>	<u>Turbidez 2 (NTU)</u>	<u>Turbidez 3 (NTU)</u>	<u>Turbidez 4 (NTU)</u>
8	163	179	146	126
10	145	145	109	84,3
12	102	90,4	92,1	64,1
14	85,2	77,8	75,3	46,9
16	73,8	57	71,2	46,1
18	71,9	56,8	69	36
20	43,3	39,5	53,8	21,9
22	36,5	33,3	29,7	16,8

Fuente: Autoría propia



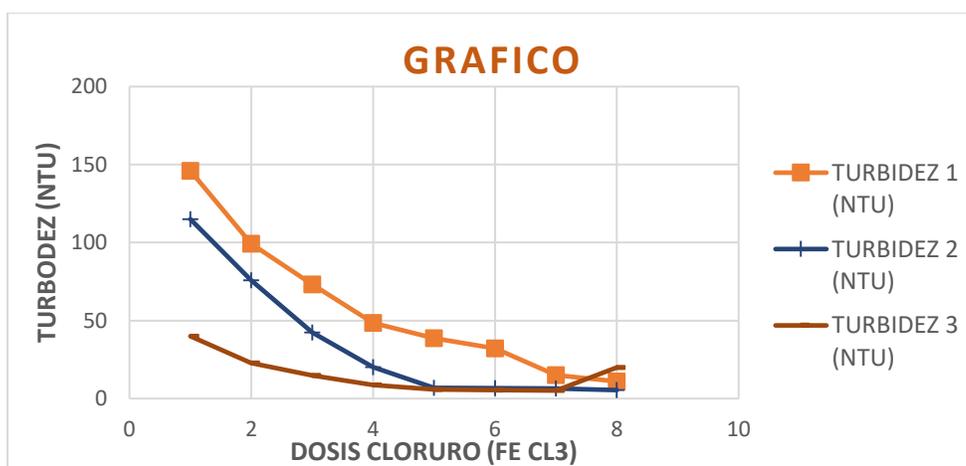
**Figura 10. Gráfico turbidez en función de dosis de cloruro (de 8 a 22 ml).**

Fuente: Autoría propia

**Tabla 3. Ensayos de turbidez en función del cloruro (de 3 a 17 ml).**

<u>Cloruro</u> <u>(ml)</u>	<u>Turbidez 1</u> <u>(NTU)</u>	<u>Turbidez 2</u> <u>(NTU)</u>	<u>Turbidez 3</u> <u>(NTU)</u>
3	146	115	40
5	99,3	75,9	22,8
7	73,2	42,4	14,9
9	48,4	20,2	8,69
11	38,6	6,89	5,93
13	32,2	6,77	5,46
15	15	6,38	5,15
17	11	5,44	20

Fuente: Autoría propia



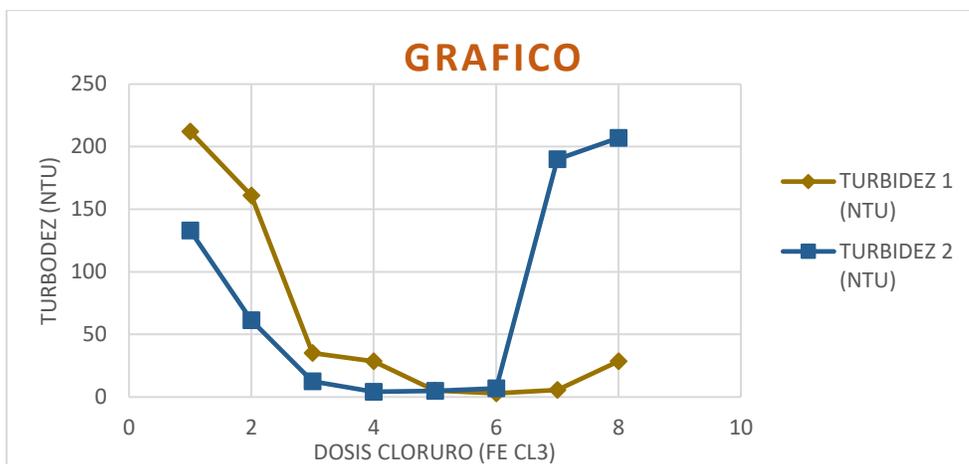
**Figura 11. Gráfico turbidez en función de dosis de cloruro (de 3 a 17 ml).**

Fuente: Autoría propia

**Tabla 4. Ensayos de turbidez en función del cloruro (de 0,5 a 13 ml).**

<u>Cloruro</u> <u>(ml)</u>	<u>Turbidez 1</u> <u>(NTU)</u>	<u>Turbidez 2</u> <u>(NTU)</u>
0,5	212	133
1	161	61,4
3	35,2	12,4
5	28,4	4,2
7	5,05	4,88
9	2,96	6,81
11	5,71	190
13	28,4	207

Fuente: Autoría propio.



**Figura 12. Gráfico turbidez en función de dosis de cloruro (de 0,5 a 13 ml).**

Fuente: Autoría propia

En los ensayos de *Jar Test* realizados afines a la dosis optima se alcanzaron múltiples resultados en relación entre la dosificación del cloruro y la turbidez final, en las tablas y figuras que se presentaron en la parte superior se muestran los resultados que se obtuvieron en la experimentación con turbiedades finales en rangos de 5 a 3 NTU que fueron los experimentos más aceptables y demostrando que las dosis optimas variaron en diferentes mililitros para que la coagulación sea efectiva.

De acuerdo a las tablas y figuras presentadas, el comportamiento entre la dosis de cloruro y la turbidez final tienden a mostrar cierta linealidad, pues en algunos ensayos se varió la dosis de cloruro de 8 a 22 mililitros y demuestra que a mayor dosis menor será la turbidez final que presenten los ensayos. Pero en otros casos no necesariamente a mayor dosis de cloruro menor turbidez final, ya que se variaron y colocaron mayores dosis y no se obtuvo turbiedades menores si no mayores. Esto quiere decir que ya se entra en la inmersión de un precipitado donde el coagulante en un cierto punto ya no hace el efecto que se requiere en el lixiviado para disminuir la turbidez.

En algunos ensayos se tiene una gran efectividad de remoción esto quiere decir que la turbidez final será muy baja, en la experimentación se llegó a obtener una turbidez final de 2,39 NTU, lo cual detalla que el lixiviado pasa de un color negro a un agua casi cristalina, el lixiviado con todo el proceso de *Jar Test*.

## **4.5. Resultados de optimización con máquinas de aprendizaje**

En este apartado se describen los resultados del algoritmo de programación que se llevaron a cabo para la implementación de la máquina de aprendizaje descritos en la sección 3.6 de materiales y métodos.

### **4.5.1. Preprocesamiento de datos.**

Los datos obtenidos de las variables en los ensayos de laboratorio, se organizaron en Tablas de Excel con el fin de poder preprocesarlos en el IDE <sup>2</sup> de RStudio. Las tablas se encuentran en la parte de anexos.

Cuando se tienen los datos en bruto, sin analizarlos de antemano, es difícil tener predicciones robustas, ya que muchos datos requieren tenerlos de una forma específica, así que es necesario la transformación del conjunto de datos. En el algoritmo se utilizó el paquete “caret” que permite trabajar con funciones específicas para dividir la muestra en datos de entrenamiento y datos validación. El preprocesamiento de datos se basa en tener los datos de entrada en una misma escala, estandarizados y normalizados. Estos métodos son, “center” que es la resta de la media de los valores, “scale” que divide los valores mediante la desviación estándar y “BoxCox” que transforma los valores distintos de cero y positivos, de esta manera se permite una mejor función de las máquinas de aprendizaje.

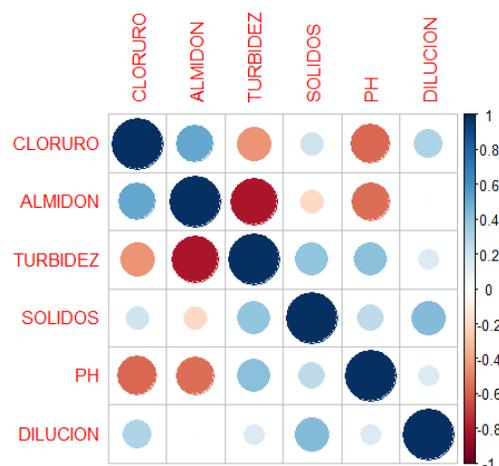
### **4.5.2. Correlación de las variables.**

En la tabla 5 se presenta la matriz de correlaciones lineales basadas en el coeficiente de Pearson que se utiliza para medir el grado de relación de las variables en la máquina de aprendizaje

Al realizar el Jar Test se determinaron las variables de análisis, pero por medio de la matriz de correlación se detectan las correlaciones que tienen las variables unas con otras.

---

<sup>2</sup> Entorno de Desarrollo Integrado (Lenguaje de programación)



**Figura 13. Relación de parámetros de la RNA.**

Fuente: Autoría propia

**Tabla 5. Relación numérica de parámetros de la RNA.**

	<u>Cloruro</u>	<u>Almidón</u>	<u>Turbidez</u>	<u>Sólidos</u>	<u>pH</u>	<u>Dilución</u>
<u>Cloruro</u>	1	0,512	-0,444	0,203	-0,571	0,305
<u>Almidón</u>	0,512	1	-0,814	-0,203	-0,55	-0,01
<u>Turbidez</u>	-0,444	-0,814	1	0,399	0,411	0,159
<u>Sólidos</u>	0,203	-0,203	0,399	1	0,259	0,433
<u>ph</u>	-0,571	-0,550	0,411	0,259	1	0,154
<u>Dilución</u>	0,305	-0,017	0,159	0,433	0,154	1

Fuente: Autoría propia

En la figura 13 se pueden observar las correlaciones lineales que existen entre las variables, El tamaño del círculo es proporcional a la intensidad de la relación entre las variables, por otra parte, la escala de color representa las correlaciones desde un valor negativo (-1, color rojo) a un valor positivo de (+1, color azul).

En la matriz de correlaciones, lo que se busca es que las variables más importantes para ingresar al modelo son las que se dan con las correlaciones más altas y estas son, las variables de turbidez, cloruro férrico, almidón y pH, de esta manera se puede determinar los porcentajes de remoción de turbidez en función del almidón y cloruro férrico teniendo en cuenta que el pH no debe variar en un amplio rango.

#### **4.5.3. División del set de entrenamiento y validación de datos.**

Aquí se establecen que porcentajes se destinan para cada sección de datos y de esta forma los datos nos permiten que el modelo tenga un mejor ajuste y no tenga deficiencias al momento del procesamiento e interacciones que efectúa la máquina de aprendizaje con la predicción del modelo. La partición quiere decir que los datos serán divididos a fuerza bruta ya que no hay métodos estadísticos que intenten uniformizarlos y compensarlos para un mejor modelo.

La división en porcentajes de datos se determinó en un 80% de entrenamiento y un 20 % de validación esto por criterios de experimentación y por criterios de autores como (Navas, 2016) que detallan que se da más peso a datos de entrenamiento y de esta forma se obtendrán mejores resultados en los datos de validación para las predicciones

#### **4.5.4. Implementación de la máquina de aprendizaje y evaluación de las métricas de regresión.**

Las máquinas de aprendizaje que se implementaron para la experimentación, fueron algoritmos lineales "LR", "GML", "GMLNET" y los algoritmos no lineales "CART", "SVM", "K-NN".

Con las métricas de regresión se comparan y evalúan los resultados que arrojaron las máquinas de aprendizaje. Para evaluar los resultados de regresión se utilizan las métricas como MAE, RMSE Y Rsquared, estas son métricas predeterminadas que son utilizadas para evaluar los algoritmos en problemas de regresión.

Las métricas de regresión como el RMSE <sup>3</sup> dan una idea de que tan bien o mal este el algoritmo, Rsquared <sup>4</sup> una medida de ajuste para las predicciones a las observaciones y MAE <sup>5</sup> nos brinda un promedio de la diferencia entre el valor observado y el valor predicho.

Mediante la programación se estimaron las métricas de regresión y se determinaron sus valores, que se de tallan en la siguiente tabla.

---

<sup>3</sup> (Root Mean Square Error) Error Cuadrático Medio.

<sup>4</sup> Coeficiente de determinación.

<sup>5</sup> Media del Valor Absoluto de los Errores.

**Tabla 6. Métricas de regresión MAE, RMSE y Rsquared.**

<b>MAE</b>							
	Min.	1st Qu.	Median	Mean	3rd Qu.	Max.	NA's
LM	2.2747362	2.655657	3.147855	3.317323	3.846201	6.198003	0
<b>SVM</b>	0.6352742	1.406805	1.936252	<b>1.849955</b>	2.310181	3.067929	0
GLM	2.2747362	2.655657	3.147855	3.317323	3.846201	6.198003	0
GLMNET	1.4978879	2.811317	3.182693	3.317447	3.872061	5.737850	0
CART	1.5237599	2.376712	2.754969	2.729326	2.927564	4.453583	0
KNN	1.0125000	1.930625	2.385000	2.442394	3.018750	3.820000	0

<b>RMSE</b>							
	Min.	1st Qu.	Median	Mean	3rd Qu.	Max.	NA's
LM	2.4923135	3.119301	3.701109	4.013272	4.870315	7.900599	0
<b>SVM</b>	0.7799994	1.665922	2.561285	<b>2.453387</b>	2.987586	4.387672	0
GLM	2.4923135	3.119301	3.701109	4.013272	4.870315	7.900599	0
GLMNET	1.6311093	3.301460	3.805881	3.997603	4.775353	7.237056	0
CART	1.9540399	3.245654	3.548734	3.558857	3.967221	5.302936	0
KNN	1.3502592	2.513768	3.451598	3.263176	3.915818	4.980859	0

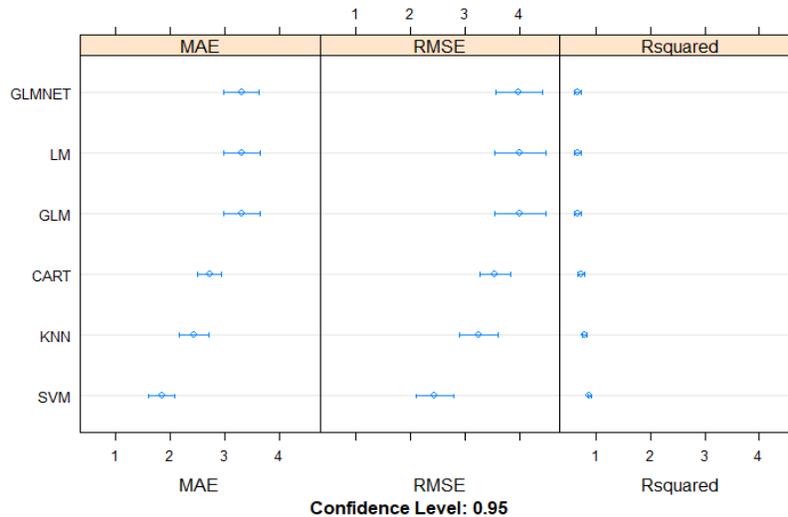
  

<b>Rsquared</b>							
	Min.	1st Qu.	Median	Mean	3rd Qu.	Max.	N
LM	0.2515805	0.5575059	0.7443748	0.6794714	0.8056542	0.9824133	0
<b>SVM</b>	0.6038549	0.8267518	0.8961028	<b>0.8864946</b>	0.9587309	0.9920230	0
GLM	0.2515805	0.5575059	0.7443748	0.6794714	0.8056542	0.9824133	0
GLMNET	0.2784605	0.5815069	0.7402962	0.6777741	0.8019774	0.9847586	0
CART	0.3692787	0.6863929	0.7464374	0.7332802	0.8609362	0.9273208	0
KNN	0.5905508	0.6961329	0.7823274	0.7931341	0.8954250	0.9692276	0

**Fuente:** Autoría propia

Se determinó por medio de la programación que la mejor máquina de aprendizaje para predecir datos en este caso fue la (SVM) Support Vector Machines ya que las métricas de regresión de acoplan de mejor manera que en comparación con las demás máquinas de aprendizaje. Por ejemplo, se puede decir que en caso de no tomar la SVM, la siguiente máquina de aprendizaje que se puede aplicar sería la (KNN) K Nearest Neighbors que tiene mejores valores en las métricas de regresión.

Como se puede observar en la tabla 6, que la mejor máquina de aprendizaje para este caso fue la SVM, dando como resultado buenos valores de las métricas para los indicadores de MAE con un valor promedio más bajo de 1.84, RMSE de valor promedio de 2.45 y un Rsquared más alto de 0.88, se debe tomar en cuenta que el MAE y RMSE deben ser escogidos por tener los valores más bajos en comparación con las demás máquinas de aprendizaje, y el Rsquared debe ser escogido por tener el valor más alto así mismo en comparación con las demás máquinas de aprendizaje. Como se sabe, los valores de las métricas de regresión dictan que máquina de aprendizaje se debe escoger.



**Figura 14. Métricas de Regresión.**

**Fuente:** Autoría propia

Como se observa en la figura 14, se asevera que la máquina de aprendizaje SVM que se encuentra en la parte inferior, detalla un MAE y RSME más bajo que están más sesgados a la izquierda y el Rsquared más alto que está más sesgado hacia la derecha, todo esto se compara con las máquinas de aprendizaje GLMNET, LM, GLM, CART y KNN.

Por otro lado, en caso de que la máquina de aprendizaje SVM no tenga buenos valores de las métricas de regresión, se pasaría a utilizar la siguiente máquina, siempre y cuando esta tenga buenas valores de ajuste, como se observa en la figura 14 , se tomaría la maquina K-NN ya que sus métricas de regresión detallan, un MAE con un valor de 2.44, el RSME con un valor de 3.99 y el Rsquared de 0.79 que indicaría una buena predicción de datos.

Todo lo detallado anteriormente se afirma mediante la experimentación del autor (Cabrera, 2011) que detalla que el rango de valores que puede tomar el RMSE va desde 0 hasta el infinito positivo y el 0 corresponde a un ajuste perfecto no en cambio los valores más grandes indican un menor ajuste en modelos de predicción. En la programación se obtuvo un valor de 2.45 pero se debe entender que es valor más bajo de todas las máquinas de aprendizaje utilizadas que se deben tomar y el MAE establece que a menor error en el algoritmo mejor ajuste en valores predichos.

#### 4.5.5. Fase de Optimización.

La fase de optimización nos permite seleccionar las variables más significativas en los resultados de tal manera saber que atributos usar y eliminar, este proceso de optimización se realiza para comparar el rendimiento de los algoritmos para buscar la mejor máquina de aprendizaje. El paquete “caret” proporciona la herramienta de Feature Selection que se utiliza para informar sobre la relevancia e importancia de los atributos en los datos e incluso seleccionar las características más importantes para el modelo.

Cuando se realizó la programación de algoritmo, se trabajó con los datos en bruto para ver qué tan bueno será el modelo de predicciones, dando así buenos resultados de relaciones entre todas las variables ingresadas. Así mismo se utilizó la herramienta de Feature Selection para eliminar la variable de almidón y calcular que tipo de correlación existía con las demás variables, pero de esta forma arrojaba una baja correlación con las variables predictoras. El proceso de optimización nos permitió comparar las variables en las diferentes máquinas de aprendizaje y determinar cuál se acopla mejor al modelado, para la disminución de errores por medio de las métricas de regresión y así poder mejorar las predicciones en el modelo.

#### 4.5.6. Validación de datos para la máquina de aprendizaje.

Una vez determinado el mejor modelo de la máquina de aprendizaje se procede a utilizarlos para hacer las predicciones sobre los datos que se requieren.

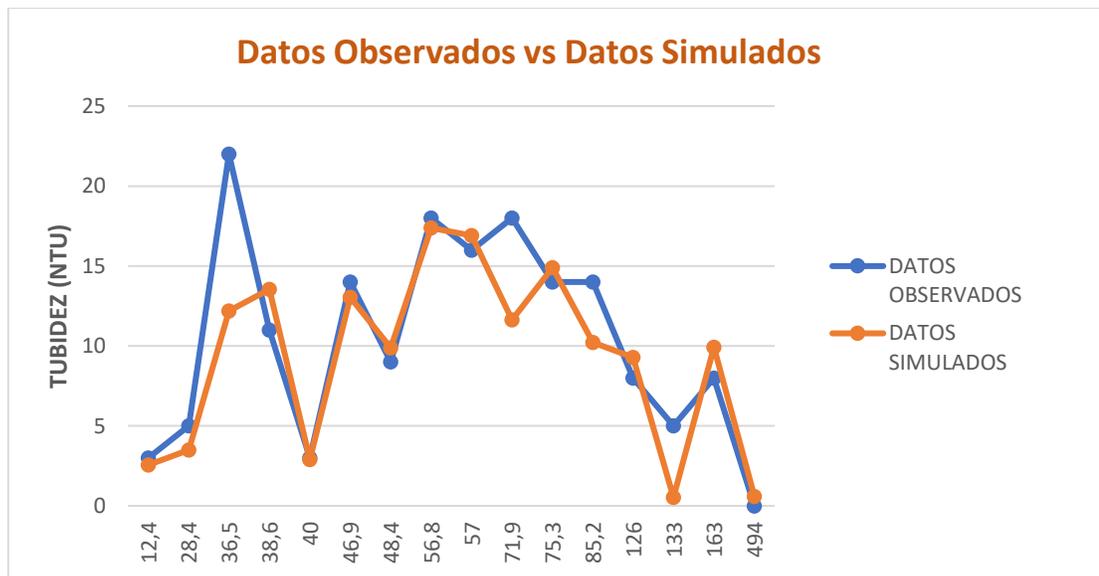
A continuación, en la tabla 7 se presentan los niveles de turbidez entre los datos observados y los datos simulados en el proceso de validación de la máquina de aprendizaje y métricas de regresión de la red.

**Tabla 7. Verificación de datos observados en función de datos simulados en la máquina de aprendizaje.**

<u>Turbidez</u> <u>(NTU)</u>	<u>Datos</u> <u>observados</u>	<u>Datos</u> <u>simulados</u>
12,4	3	2,56
28,4	5	3,49
36,5	22	12,19
38,6	11	13,54
40	3	2,9

46,9	14	13,05
48,4	9	9,88
56,8	18	17,38
57	16	16,9
71,9	18	11,64
75,3	14	14,89
85,2	14	10,23
126	8	9,29
133	5	0,53
163	8	9,92
494	0	0,6

Fuente: Autoría propia



**Figura 15. Datos observados en función de datos simulados por la máquina de aprendizaje.**

Fuente: Autoría propia

Al observar la Figura 15, se tomó en consideración que, para validar el modelo, se ha seguido el proceso de la métrica de regresión Rsquared, teniendo en cuenta siempre que el ajuste que ofrece la recta sobre la nube de puntos es bueno, por medio de la programación detalla un coeficiente de correlación de Pearson casi cercano a 1 y esto quiere decir que los datos observados los cuales se obtuvieron a lo largo de todo el proceso de Jar Test se ajustan a los datos simulados que se obtuvieron en la ejecución o programación de la red.

Como se puede observar en la tabla 7 y figura 15 presentada anteriormente, la efectividad de la red al predecir los datos de la dosis de cloruro sigue casi una misma tendencia a los datos observados; La máquina de aprendizaje se ejecuta y funciona de buena manera para predecir valores a diferentes escenarios.

Esto se puede afirmar mediante la experimentación de los autores (Cortés & Achedad, 2014), que indican que, la evaluación de predicciones se utilizan para medir el grado de bondad de la predicción realizada sobre las variables de interés; para expresar exactitud de una predicción se lo realiza mediante el valor observado de la variable de interés y el valor que se predice y así evitar compensación de errores de una imagen global de un buen ajuste de modelos a los datos reales,

#### **4.5.7. Fase de Forecasting.**

Una vez que se ha finalizado y se ha encontrado el modelo de la máquina de aprendizaje preciso, se debe dar por finalizado el modelo y así utilizar el modelo para realizar las predicciones de los datos.

Para verificar que la red funcione y prediga los valores de cloruro férrico, se procede a trabajar con diferentes datos que ya se han obtenido en los ensayos de laboratorio. Al cambiar los datos observados se procederá a estimar valores predichos esto quiere decir que se encontraran la dosis de cloruro en función de las variables de entrada como son el almidón, turbidez, solidos, pH y dilución.

**Tabla 8. Datos predichos de las dosis de cloruro.**

<u>Cloruro</u>	<u>Almidón</u>	<u>Turbidez</u>	<u>Solidos</u>	<u>pH</u>	<u>Dilución</u>
11,52	5	84.5	7475	6.61	0.000
10,5	5	177.0	7295	6.70	9.000
11,32	5	140.0	10435	6.67	9.000
16,67	5	67.5	6190	6.21	4.000
13,29	5	45.0	14520	6.38	2.334
4,26	0	475.0	7480	7.64	1.000
7,53	5	41.6	6045	6.64	1.000
11,18	5	5.9	5935	6.21	1.000
14,16	5	5.0	5630	5.86	1.000

**Fuente:** Autoría propia

De esta manera se comprueba que la máquina de aprendizaje realizada funciona de buena manera y que predice los datos de cloruro férrico para cualquier escenario que se plantee.

Esto quiere decir que la red predice los valores en función de las variables de entrada que se ingresen en la red. Los niveles de cloruro férrico que se obtienen en la salida de la red son coherentes como se puede ver en la tabla, donde para una turbidez de 84.5 NTU, una dilución de 0 se estima que se necesita de 11,52 ml de cloruro férrico para disminuir la turbidez. Por otro lado, para una turbidez de 41.6 y una dilución de 1, el cloruro a utilizar será de 7.53 ml, es de menor valor ya que es un líquido más diluido y por ende menos turbidez.

Como se puede observar en la tabla 8; el almidón, turbidez, sólidos, pH y dilución son las variables de entrada que toma la red para poder estimar las dosis de cloruro, ya que en la experimentación se producen 2 escenarios, el primer escenario se da al adicionar pequeñas cantidades el efecto no se concretaba de buena manera y el segundo escenario se da cuando se adiciona gran cantidad de almidón no reaccionaba de buena manera ósea su efecto no es el esperado y no cumple con la remoción.

## CAPÍTULO V

### 5. CONCLUSIONES

- Los lixiviados de los rellenos sanitarios, tienen efectos contaminantes al medio ambiente, perjudican la salud de los habitantes del área de influencia que no puede ser menos de 500 metros de donde se encuentre ubicado el relleno, por lo que se halla necesario poder tratar estos líquidos de forma segura y apropiada, de tal forma que los procesos que se detallan en este estudio sean aplicados como una viabilidad técnica garantizando así un proceso eficiente en cualquier tipo de relleno sanitario.
- Mediante el presente estudio se comprobó que al mezclar el almidón de yuca (agente coadyuvante) y cloruro férrico ( $\text{FeCl}_3$ ) (agente coagulante) logran un gran potencial efecto en la coagulación- floculación que ayudan de gran manera al tratamiento de lixiviados para clarificar el líquido en cuestión con casi una remoción de 98,31% y así también disminuir su carga contaminante.
- Por medio de la experimentación y discusión con autores, se concluye que, entre todos los coagulantes de origen natural, el almidón de yuca es el más fácil y efectivo de obtener ya que no es necesario de un largo proceso y se puede conseguir en grandes cantidades.
- Es importante acotar que las máquinas de aprendizaje están establecidas por las métricas de regresión las cuales nos detallan cuan bien o mal será el modelo de predicción.
- La efectividad de la máquina de aprendizaje va a depender de la definición de las variables de entrada que influyan directamente en la predicción de los datos, también de la cantidad y calidad de datos que se tengan para el set de entrenamiento y validación, de igual forma de los algoritmos que se ejecuten en la programación ya que así se determinaran los resultados de las predicciones y estos se presenten con los menores valores de métricas de errores y sean más resultados predichos más precisos.

- El tiempo empleado para la determinación de las dosis de cloruro férrico y almidón en el laboratorio mediante el ensayo de jarras o Jar Test fue muy alto, y lo que se quiere estimar con los modelos computacionales como Machines Learning son disminuir el tiempo de las operaciones en laboratorios, así como también de los costos operacionales ya que los biopolímeros son más económicos y amigables con el ambiente, por medio de la red se podrán ingresar datos de los diferentes escenarios o datos tomadas del líquido estudiado y así poder predecir las dosis que se requieren para las características ingresadas.
- Este trabajo es de gran aporte para ser desarrollado en cualquier tipo de relleno sanitario, ya que no existe solo una forma de poder tratar el lixiviado, algo importante que se debe tomar en cuenta es también la parte operativa del relleno ya que así se puede facilitar su aplicación.
- Los resultados que se obtuvieron en el presente trabajo logran comprobar que las mezclas de cloruro férrico con almidón de yuca que es de origen natural dan un buen tratamiento en remoción de turbidez, de esta manera la mezcla de biopolímeros es importante ya que ayuda aminorar el impacto ambiental y algo importante es eliminar el uso de coagulantes metálicos.
- Las métricas de regresión son fundamentales al momento de aplicar las máquinas de aprendizaje, ya que estos nos indican que algoritmo se acopla más al momento de la clasificación de datos, las métricas evalúan el grado de predicción de las variables de interés y se trata de medir valores reales para así determinar con exactitud las predicciones.

## CAPÍTULO VI

### 6. RECOMENDACIONES

- El uso de polímeros naturales son una gran opción de cambio para los polímeros químicos que son más difíciles de asimilar para el ambiente en donde se lo utilice, de esta manera los polímeros naturales no manifiestan ningún grado de toxicidad al ser utilizados en el ambiente y esto extiende las posibilidades de poder experimentar con cualquier tipo de polímero naturales en función de tipos de aguas municipales y de las industrias.
- En este caso un punto adicional para la red, sería de evaluar cual es el valor óptimo cuando se ingresen todas las variables, lo que hace la red es dar los valores que queremos por cada nivel de turbidez pero un paso más para que sea más eficiente sería que evalué todos los datos de entradas y prediga en valor óptimo para la turbidez tomando en cuenta teorías como la inmersión de un precipitado, en este caso para menores valores de turbidez mayores dosis de cloruro y esto altera los resultados.
- Se recomienda que se tenga un estudio a fondo sobre las características y funcionalidades del líquido a tratar para cuando no genere mayores inconvenientes se experimente.
- Se propone la utilización de Feature Selection (herramienta del paquete “caret”), ya que puede mejorar el rendimiento del modelo. Esto es mediante la eliminación de predictores con posibilidad o influencia negativa y proporcionar implementaciones más rápidas y rentables por la disminución en el número de características que entran en el modelo.
- Se recomienda que las mediciones que se realicen sean con equipos capaces de monitorear turbiedades con valores mayores de 1000 NTU, ya que para este estudio se tomó como valor mayor de turbidez los 1000 NTU, pero los valores sobrepasaban este rango, de esta manera se podrá determinar mejor el comportamiento del lixiviado y poder mejorar el proceso en la red y tener datos más reales y precisos.

- Las características de los lixiviado que se encuentran en las piscinas del relleno sanitario varían de acuerdo a la época del año en la que se encuentre, algo adicional para futuros trabajo es que se puede realizar las evaluaciones de los procedimientos en épocas de lluvias y sequias para diferenciar su comportamiento y determinar cuándo es más efectivo la aplicación de este tratamiento.
- Se sugiere que el trabajo planteado sea aplicado en otros rellenos sanitarios, puede ser a nivel de las regiones de la costa u oriente, ya que los tratamientos son ajustados para cada lixiviado de los diferentes rellenos sanitarios y así poder establecer las diferencias o similitudes por las diferentes propiedades que se tienen en las regiones del Ecuador o con cualquier tipo de agua, así de esta manera se podrá evidenciar la eficiencia del trabajo.

## REFERENCIAS BIBLIOGRAFICAS

- Abdon, I. determinación de la dosis óptima del coagulante sulfato de aluminio aplicado en la planta de tratamiento de agua de la central termoeléctrica “el descanso”. , El Escorial 14,28 (2012).
- Alvarez, J. (2016). Machine Learning y Support Vector Machines: porque el tiempo es dinero.
- Asano, T. (2014). *Wastewater engineering: treatment and reuse*. 201–208.
- Bravo, M. (2017). Coagulantes y floculantes naturales usados en la reducción de turbidez, solidos suspendidos, colorantes y metales pesados en aguas residuales. Bogota: Universidad Distrital Francisco Jose de Caldas.
- Bernado, O., & Hernan, C. (2002). *La Yuca en el Tercer Milenio. sistemas Modernos de Produccion, Procesamiento, Utilizacion y Comercializacion*. Cali, Colombia: CIAT.
- Brett, L. (2015). *Machine Learning with R*. Birmingham, UK: Packt Publishing Ltd.
- Brumovsky, L. *Quimica del Almidon*. , (2014).
- Cabrera, J. (2011). *Calibración de Modelos Hidrológicos*. 1.
- Cabera, G., & Ramirez, J. (2014). Almidón extraído de la yuca (Manihot Esculenta Crantz) como coagulante alternativo para tratamiento del agua de la quebrada Yamuesquer Municipio de Potosí. Potosi: Universidad de Potosi.
- Carrasco, M. (2016). *Técnicas de regularización en regresión: implementación y aplicaciones*. Universidad de Sevilla.
- Castrillon, D., & Giraldo, M. (2012). *Determinación de las dosis óptimas del coagulante sulfato de aluminio granulado tipo b en función de la turbiedad y el color para la potabilización del agua en la planta de tratamiento de villa santana*. Daniela Castrillón bedoya maría de los ángeles Giraldo universidad tecnológica de Pereira.
- Castro, L. M. A. (2016). Variación en la reducción de la turbiedad de lixiviados del relleno sanitario la esmeralda, mediante un proceso de coagulación/floculación ayudado por almidón de plátano y aguas termales (Universidad Catolica de

- Manizales). <https://doi.org/https://doi.org/10.3929/ethz-b-000238666>
- Castaño, D. (2011). Analisis de la influencia de dos materias primas coagulantes en el aluminio residual del agua tratada. Pereira. Colombia : Universidad Tecnologica de Pereira.
- COOTAD. (2010). Codigo Organico Organizacion Territorial Autonomia Descentralizacion. Ecuador.
- Comisión Nacional del Agua. *Manual de agua potable, alcantarillado y saneamiento: diseño de plantas potabilizadoras tipo de tecnología simplificada.* , (2007).
- Cordero, R. (2014). Ingeniería Sanitaria y Ambiental. Mexico: Texere: DISA.
- Cortés, P., & Achedad, L. (2014). *Ingeniería de organización Modelos y Aplicaciones* (Ediciones).
- Cuadro, W., & Rodas, J. (2017). *Alternativa para sustitución de coagulantes metálicos aplicando almidón de yuca y moringa oleífera en tratamiento de aguas superficiales*". Universidad de Guayaquil.
- Desiderio, F. (2017). Optimización del proceso de extracción de almidón de yuca y estudio de su influencia como floculante en el tratamiento de aguas. Guayaquil: escuela superior politécnica del litoral.
- Elsevier. (2016). *Modelos de aprendizaje computacional en reumatología Machine learning models in rheumatology.* 2(2), 77–78.
- Espinosa, V. (2008). *Estudios Estructurales de Almidón de Fuentes No Convencionales : Mango ( Mangifera indica L .) Y Plátano ( Musa paradisiaca L .).* Instituto Politecnico Nacional.
- FAO. *Guía técnica para producción y análisis de almidón de yuca.* , (2007).
- Fontalvo, T., De la HOZ, E., & Olivos, S. (2019). *Metodología de Análisis Envolvente de Datos ( DEA ) - GLMNET para la Evaluación y Pronóstico de Eficiencia Financiera en una Methodology of Data Envelopment Analysis ( DEA ) - GLMNET for Assessment and Forecasting of Financial Efficiency in a Free Trade Z.* 30(5), 263–270.
- Gonzalez, L. (2018). Evaluando el error en los modelos de regresión.

- Gonzalez, P. (2017). El algoritmo K-NN y su importancia en el modelado de datos.
- Guzmán, L., Villabona, Á., Tejada, C., & García, R. (2013). Reducción de la turbidez del agua usando coagulantes naturales : reduction of water turbidity using natural coagulants : a review. *Revista UDCA*, 253–262.
- Hernan, R. (2009). *Evaluación del proceso de coagulación – floculación de una planta de tratamiento de agua potable* (Universidad Nacional de Colombia). Retrieved from <http://www.albayan.ae>
- Izuareta, F. (2011). "Redes Neuronales Artificiales," . Chile: Universidad de Concepcion.
- Jimenez, T., & Medina, J. (2017). *Influencia de la dilución del sulfato de aluminio en la eficiencia de la coagulación en la potabilización del agua*. Escuela politécnica nacional.
- Lopez, M. (2017). Tratamiento de residuos solidos urbanos o municipales. Madrid: Editorial CEP.
- Martel, A. (2010). Tratamiento de aguas. Argentina.
- Martínez-meyer, E. (2016). *Algoritmos de Modelación ( o las máquinas de chorizos )*.
- Mejia, M., & Pinos, A. (2012). Los problemas ambientales producidos por el relleno sanitario de Pichacay en la parroquia "Santa Ana" del cantón cuenca. Universidad de cuenca.
- Mendoza, J. (2018). Arboles de decisión con R - Clasificación.
- Moreira, M. F. D. (2017). *Optimización del proceso de extracción de almidón de yuca y estudio de su influencia como floculante en el tratamiento de aguas*. Escuela Superior Politecnica del Litoral.
- Navas, D. (2016). Ciencias de la computación & Inteligencia Artificial. Estados Unidos: Lodz University of Technology.
- Orduz, O., & Portilla, J. (2017). *Determinación de las curvas características de la sedimentación tipo ii con diferentes coagulantes comerciales a nivel laboratorio*. Universidad Catolica de Colombia.

- Osorno, R. (2009). "Evaluación del proceso de coagulación-floculación de una planta de tratamiento de agua potable." . Facultad de Minas.
- Romero, M. (2012). *Tratamientos utilizados en potabilización de agua*. (08), 1–12.
- Salazar, S., Rojas, G., & Carrilo, Y. (2016). Uso de coagulantes orgánicos e inorgánicos en el proceso físico-químico coagulación - floculación del afluente de un sistema lóxico. . Colombia: Universidad Popular del Cesar.
- Salas, R. (2004). *Redes Neuronales Artificiales*. 1–7.
- Shak, k., & Wu, T. (2014). Coagulation-flocculation treatment of high-strength agroindustrial wastewater using natural *Cassia obtusifolia* seed gum: treatment efficiencies and flocs characterization. *Ghem. Eng.*
- Solis, R., Laines, J., & Hernández, J. (2012). Mezclas con potencial coagulante para clarificar aguas superficiales. *Revista Internacional de Contaminación Ambiental*, 28(3), 229–236.
- Sprockela, J., Diaztagleb, J., Alzatec, W., & González, E. (2014). *Redes neuronales en el diagnóstico del infarto agudo de miocardio John*. 21(4), 9.
- Tablada, C. J. (2010). "Redes Neuronales Artificiales". Buenos Aires: G.A.T.
- Tatsi, A., & Zouboulis, A. (2002). A field investigation of the quantity and quality of leachate from a municipal solid waste landfill in a Mediterranean climate. Thessaloniki, Greece: Division of Chemical Technology, Department of Chemistry, Aristotle University.
- Tchobanoglous, G., Theissen, H., & Eliassen, R. (1982). *Desechos sólidos principios de ingeniería y administración: 2da parte*. Venezuela.
- Utrera, G. (2017). *Uso de algoritmos de aprendizaje automático aplicados a bases de datos genéticos*.
- Zerbatto, M., Carrera, E., Eliggi, M. S., Modini, L., Vaira, S., Nosedá, J. C., & Abramovich, B. (2009). *Cloruro Férrico para la coagulación optimizada y remoción de enteroparásitos en agua*. 18–26.

## ANEXOS

### Anexo 1. Registro Fotográfico

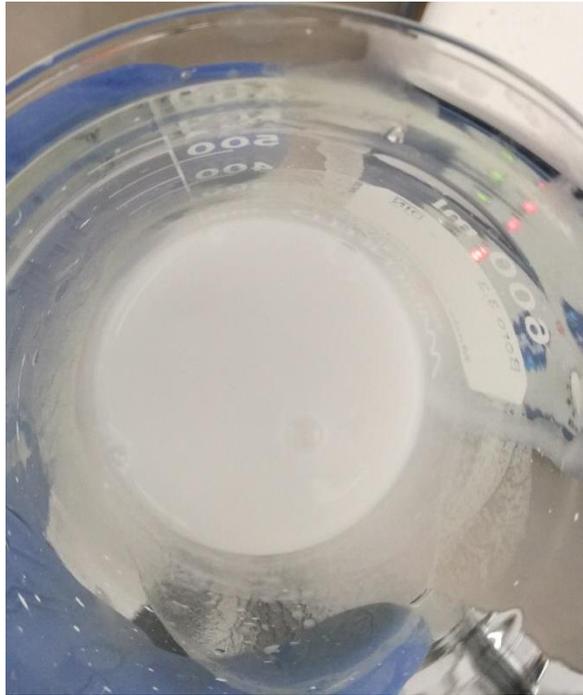
Prueba de jarras, proceso de sedimentación.



Pulpa de yuca, previo a obtener biopolimero.



Obtención de biopolímero de la yuca.



Canal de lixiviados antes de llegar a las piscinas.



Toma de muestras de lixiviados.



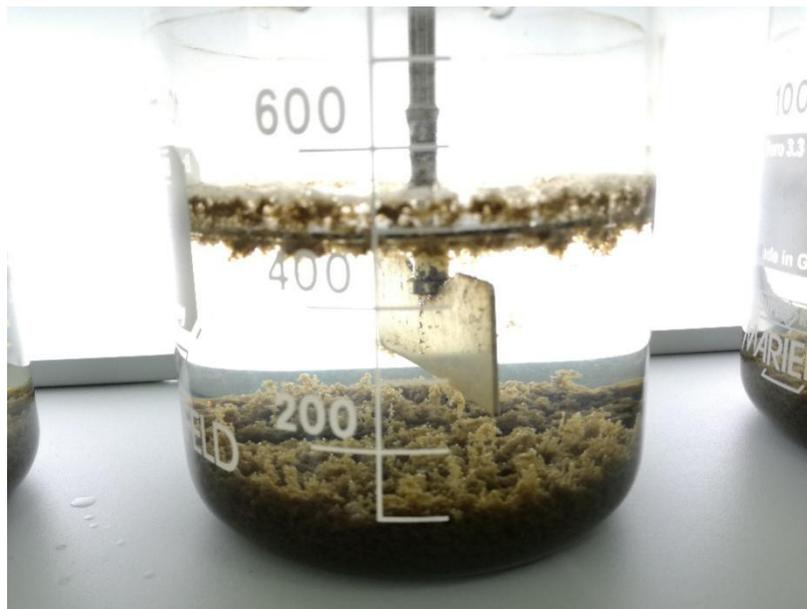
Lixiviados, cloruro férrico y almidón (antes Jar Test)



Medición de pH.



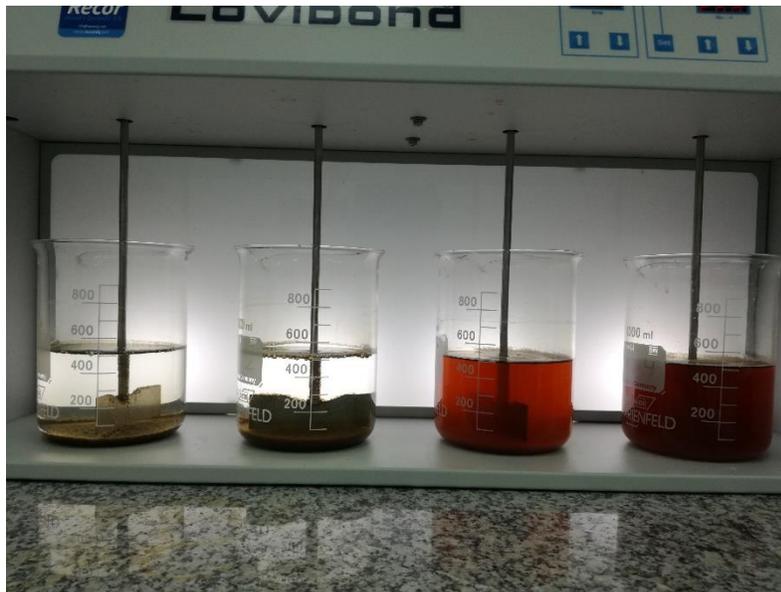
Formación de flocs.



## Muestras para mediciones de turbidez



## Inmersión de un precipitado.



Jar Testa (turbidez más baja).



## Anexo 2. Tablas

Tabla de pruebas realizadas en el ensayo de jarras

<b>DOSIS DE CLORURO FERRICO (FeCL3) + ALMIDÓN</b>					
<b>C1 (NORMAL SIN DILUCION)</b>					
<b>DOSIS (FeCL3)</b>	<b>DOSIS ALMIDON</b>	<b>TURBIDEZ (NTU)</b>	<b>SOLIDOS TOTALES</b>	<b>PH</b>	<b>DILUCION</b>
0	0	1000	14050	7,8	0
8	5	163	9630	6,74	0
8	5	163	9000	6,74	0
10	5	145	3950	6,67	0
10	5	145	3000	6,67	0
12	5	102	10830	6,65	0
12	5	102	10000	6,65	0
14	5	85,2	7950	6,61	0
14	5	85,2	7000	6,61	0
16	5	73,8	10040	6,59	0
16	5	73,8	5320	6,59	0
18	5	71,9	9670	6,51	0
18	5	71,9	7120	6,51	0
20	5	43,3	9370	6,4	0
20	5	43,3	7730	6,4	0
22	5	36,5	7030	6,31	0
22	5	36,5	8590	6,31	0
<b>C2 (DILUCION 9 LIXIVIADO + 1 AGUA)</b>					
<b>DOSIS (FeCL3)</b>	<b>DOSIS ALMIDON</b>	<b>TURBIDEZ (NTU)</b>	<b>SOLIDOS TOTALES</b>	<b>PH</b>	<b>DILUCION</b>
0	0	1000	11530	7,67	9
8	5	179	4070	6,7	9
8	5	179	10520	6,7	9
10	5	145	10220	6,67	9
10	5	145	10650	6,67	9
12	5	90,4	4250	6,55	9
12	5	90,4	4300	6,55	9
14	5	77,8	5690	6,48	9
14	5	77,8	10250	6,48	9
16	5	57	11010	6,43	9
16	5	57	11530	6,43	9

18	5	56,8	11020	6,36	9
18	5	56,8	11130	6,36	9
20	5	39,5	11000	6,3	9
20	5	39,5	9370	6,3	9
22	5	33,3	11120	6,21	9
22	5	33,3	10920	6,21	9
<b>C3 (DILUCION 8 LIXIVIADO + 2 AGUA)</b>					
<b>DOSIS (FeCL3)</b>	<b>DOSIS ALMIDON</b>	<b>TURBIDEZ (NTU)</b>	<b>SOLIDOS TOTALES</b>	<b>PH</b>	<b>DILUCION</b>
0	0	1000	10050	7,41	4
8	5	146	8090	6,7	4
8	5	146	9760	6,7	4
10	5	109	9420	6,65	4
10	5	109	9460	6,65	4
12	5	92,1	8090	6,5	4
12	5	92,1	8740	6,5	4
14	5	75,3	9570	6,37	4
14	5	75,3	9410	6,37	4
16	5	71,2	6000	6,23	4
16	5	71,2	4870	6,23	4
18	5	69	4930	6,21	4
18	5	69	7450	6,21	4
20	5	53,8	8860	6,1	4
20	5	53,8	7840	6,1	4
22	5	29,7	8850	6,04	4
22	5	29,7	5080	6,04	4
<b>C4 (DILUCION 7 LIXIVIADO + 3 AGUA)</b>					
<b>DOSIS (FeCL3)</b>	<b>DOSIS ALMIDON</b>	<b>TURBIDEZ (NTU)</b>	<b>SOLIDOS TOTALES</b>	<b>PH</b>	<b>DILUCION</b>
0	0	1000	18460	7,02	2,33
8	5	126	28640	6,68	2,33
8	5	126	10420	6,68	2,33
10	5	84,3	27620	6,56	2,33
10	5	84,3	18250	6,56	2,33
12	5	64,1	19910	6,5	2,33
12	5	64,1	13750	6,5	2,33
14	5	46,9	20510	6,38	2,33
14	5	46,9	8530	6,38	2,33

16	5	46,1	8810	6,24	2,33
16	5	46,1	8370	6,24	2,33
18	5	36	8390	6,17	2,33
18	5	36	9530	6,17	2,33
20	5	21,9	8050	6,01	2,33
20	5	21,9	5460	6,01	2,33
22	5	16,8	7310	5,94	2,33
22	5	16,8	6360	5,94	2,33
<b>C5 (DILUCION 6 LIXIVIADO + 4 AGUA)</b>					
<b>DOSIS (FeCL3)</b>	<b>DOSIS ALMIDON</b>	<b>TURBIDEZ (NTU)</b>	<b>SOLIDOS TOTALES</b>	<b>PH</b>	<b>DILUCION</b>
0	0	1000	8070	7,15	1,5
3	5	146	6980	7,13	1,5
3	5	146	7230	7,13	1,5
5	5	99,3	7280	6,9	1,5
5	5	99,3	6920	6,9	1,5
7	5	73,2	7040	6,73	1,5
7	5	73,2	7420	6,73	1,5
9	5	48,4	6610	6,54	1,5
9	5	48,4	6410	6,54	1,5
11	5	38,6	6780	6,31	1,5
11	5	38,6	7060	6,31	1,5
13	5	32,2	7690	6,16	1,5
13	5	32,2	6440	6,16	1,5
15	5	15	7570	6,1	1,5
15	5	15	5680	6,1	1,5
17	5	11	6370	5,96	1,5
17	5	11	6400	5,96	1,5
<b>C6 (DILUCION 5 LIXIVIADO + 5 AGUA)</b>					
<b>DOSIS (FeCL3)</b>	<b>DOSIS ALMIDON</b>	<b>TURBIDEZ (NTU)</b>	<b>SOLIDOS TOTALES</b>	<b>PH</b>	<b>DILUCION</b>
0	0	494	7480	7,64	1
3	5	115	5270	7,06	1
3	5	115	5530	7,06	1
5	5	75,9	7780	6,91	1
5	5	75,9	5910	6,91	1
7	5	42,4	5990	6,64	1
7	5	42,4	6100	6,64	1

9	5	20,2	5270	6,38	1
9	5	20,2	6590	6,38	1
11	5	6,89	5970	6,21	1
11	5	6,89	5900	6,21	1
13	5	6,77	4840	6,09	1
13	5	6,77	5790	6,09	1
15	5	6,38	6290	5,94	1
15	5	6,38	5810	5,94	1
17	5	5,44	5620	5,86	1
17	5	5,44	5640	5,86	1
<b>C7 (DILUCION 4 LIXIVIADO + 6 AGUA)</b>					
<b>DOSIS (FeCL3)</b>	<b>DOSIS ALMIDON</b>	<b>TURBIDEZ (NTU)</b>	<b>SOLIDOS TOTALES</b>	<b>PH</b>	<b>DILUCION</b>
0	0	307	2040	7,58	0,66
3	5	40	4990	6,95	0,66
3	5	40	4015	6,95	0,66
5	5	22,8	3860	6,69	0,66
5	5	22,8	2450	6,69	0,66
7	5	14,9	4510	6,48	0,66
7	5	14,9	4460	6,48	0,66
9	5	8,69	4080	6,18	0,66
9	5	8,69	4220	6,18	0,66
11	5	5,93	1000	5,66	0,66
11	5	5,93	4190	5,66	0,66
13	5	5,46	3890	5,71	0,66
13	5	5,46	4600	5,71	0,66
15	5	5,15	4420	5,75	0,66
15	5	5,15	5500	5,75	0,66
17	5	217	2070	4,91	0,66
17	5	217	3330	4,91	0,66
<b>C8 (DILUCION 3 LIXIVIADO + 7 AGUA)</b>					
<b>DOSIS (FeCL3)</b>	<b>DOSIS ALMIDON</b>	<b>TURBIDEZ (NTU)</b>	<b>SOLIDOS TOTALES</b>	<b>PH</b>	<b>DILUCION</b>
0	0	300	5520	7,68	0,42
0,5	5	212	3420	7,28	0,42
0,5	5	212	3510	7,28	0,42
1	5	161	4060	7,19	0,42
1	5	161	4090	7,19	0,42

3	5	35,2	4360	6,69	0,42
3	5	35,2	4490	6,69	0,42
5	5	28,4	2370	6,57	0,42
5	5	28,4	2300	6,57	0,42
7	5	5,05	3630	6,01	0,42
7	5	5,05	3580	6,01	0,42
9	5	2,96	3560	5,8	0,42
9	5	2,96	3540	5,8	0,42
11	5	5,71	3120	5,5	0,42
11	5	5,71	3130	5,5	0,42
13	5	28,4	3180	5,09	0,42
<b>C9 (DILUCION 2 LIXIVIADO + 8 AGUA)</b>					
<b>DOSIS (FeCL3)</b>	<b>DOSIS ALMIDON</b>	<b>TURBIDEZ (NTU)</b>	<b>SOLIDOS TOTALES</b>	<b>PH</b>	<b>DILUCION</b>
13	5	28,4	3140	5,09	0,42
0	0	291	2950	7,56	0,25
0,5	5	133	2540	7,37	0,25
0,5	5	133	2580	7,37	0,25
1	5	61,4	2820	7,1	0,25
1	5	61,4	2790	7,1	0,25
3	5	12,4	2460	6,6	0,25
3	5	12,4	2480	6,6	0,25
5	5	4,2	2750	5,8	0,25
5	5	4,2	1810	5,8	0,25
7	5	4,88	2590	5,44	0,25
7	5	4,88	2600	5,44	0,25
9	5	6,81	2570	5,1	0,25
9	5	6,81	2460	5,1	0,25
11	5	190	2780	4,45	0,25
11	5	190	2690	4,45	0,25
13	5	207	2250	4,61	0,25
13	5	207	2300	4,61	0,25
<b>C10 (DILUCION 1 LIXIVIADO + 9 AGUA)</b>					
<b>DOSIS (FeCL3)</b>	<b>DOSIS ALMIDON</b>	<b>TURBIDEZ (NTU)</b>	<b>SOLIDOS TOTALES</b>	<b>PH</b>	<b>DILUCION</b>
0	0	132,1	1520	7,68	0,11
0,1	5	47	1470	7,28	0,11
0,1	5	47	1300	7,28	0,11

0,2	5	26,8	1130	7,19	0,11
0,2	5	26,8	1380	7,19	0,11
0,4	5	19,3	1280	6,69	0,11
0,4	5	19,3	1370	6,69	0,11
0,8	5	4,71	1290	6,57	0,11
0,8	5	4,71	1390	6,57	0,11
2	5	2,39	560	6,01	0,11
2	5	2,39	960	6,01	0,11
4	5	1,86	1250	5,8	0,11
4	5	1,86	1240	5,8	0,11
6	5	87,2	1430	5,5	0,11
6	5	87,2	780	5,5	0,11
8	5	194	2060	5,09	0,11
8	5	194	1910	5,09	0,11



PERMISO DEL AUTOR DE TESIS PARA SUBIR AL REPOSITORIO  
INSTITUCIONAL

Yo, **Carlos Andrés Valdivieso Valverde** portador(a) de la cédula de ciudadanía N° 0704612357. En calidad de autor/a y titular de los derechos patrimoniales del trabajo de titulación "**Optimización de biopolímeros en el proceso de coagulación floculación para el tratamiento de lixiviados en la ciudad de Cuenca mediante el uso de redes neuronales artificiales**" de conformidad a lo establecido en el artículo 114 Código Orgánico de la Economía Social de los Conocimientos, Creatividad e Innovación, reconozco a favor de la Universidad Católica de Cuenca una licencia gratuita, intransferible y no exclusiva para el uso no comercial de la obra, con fines estrictamente académicos, Así mismo; autorizo a la Universidad para que realice la publicación de éste trabajo de titulación en el Repositorio Institucional de conformidad a lo dispuesto en el artículo 144 de la Ley Orgánica de Educación Superior.

Cuenca, 31 de enero de 2020

F: .....  
  
Carlos Andrés Valdivieso Valverde  
C.I. 0704612357