



UNIVERSIDAD CATÓLICA DEL NORTE
FACULTAD DE INGENIERÍA Y CIENCIAS GEOLÓGICAS
DEPARTAMENTO DE INGENIERÍA DE SISTEMAS DE COMPUTACIÓN

**DESARROLLO DE INSTRUMENTO PROTOTIPO BASADO
EN UN MODELO DE REDES NEURONALES PARA
PREDICCIÓN DE NIVEL DE LODOS Y CONTENIDO DE
SÓLIDOS EN ESPESADORES INDUSTRIALES**

Tesis para optar al grado de Magister en Ingeniería Informática

MAURICIO LEIVA PÉREZ

Profesores Guías:

Dr. Claudio Acuña Pérez

Dr. Carlos Pon Soto

Antofagasta, Chile

Mayo 2012

A mi Madre

ÍNDICE

ÍNDICE DE FIGURAS.....	v
ÍNDICE DE TABLAS	viii
RESUMEN.....	ix
CAPÍTULO 1: INTRODUCCIÓN	1
CAPÍTULO 2: DISEÑO DEL SENSOR BASADO EN PERFILES DE CONDUCTIVIDAD	7
2.1 Definición de conductividad.....	7
2.2 Medición de conductividad.....	8
2.3 Modelo de Maxwell	11
2.4 Criterios de diseño del sensor multielectrodos	13
2.4.1 Diseño de la barra multielectrodos	13
2.4.2 Diseño del electrodo	15
CAPÍTULO 3: DISEÑO, MONTAJE DEL HARDWARE DEL INSTRUMENTO Y DESARROLLO DE SOFTWARE DE CONECTIVIDAD.....	21
3.1 Descripción del instrumento de medición	21
3.2 Adquisición de datos.....	23
3.2.1 Configuración del hardware	24
3.2.2 Conectividad de software	25
3.2.3 Programación para captura e historización de datos	27
3.3 Calibración del sensor multielectrodos.....	30
CAPÍTULO 4: ALGORITMOS USADOS EN REDES NEURONALES ..	35
4.1 Descripción de las redes neuronales	35
4.2 Algoritmo de Retropropagación	36
4.3 Entrenamiento Rápido	38
4.4 Mejorando la Generalización de la Red.....	39

CAPÍTULO 5: DESARROLLO DE ESTRATEGIA DE ENTRENAMIENTO PARA OPTIMIZAR LA RED A IMPLEMENTAR	42
5.1 Estrategia para el ajuste de la red.....	42
5.2 Modelado de curvas de sedimentación	44
5.3 Obtención del número de neuronas en la capa oculta con datos simulados	48
5.4 Ajuste de modelo generalizado para todos los tipos de curvas	56
CAPÍTULO 6: VALIDACIÓN EXPERIMENTAL CON RELAVES CHUQUICAMATA.....	64
6.1 Validación y calibración de la red neuronal con 3 neuronas en capa oculta.....	66
6.2 Validación y calibración de la red neuronal con 2 neuronas en capa oculta.....	71
CAPÍTULO 7: CONCLUSIONES Y TRABAJO FUTURO	76
7.1 Conclusiones	76
7.2 Trabajo Futuro	77
GLOSARIO Y ABREVIATURAS.....	78
APÉNDICE A	79
APÉNDICE B	81
APÉNDICE C	82
APÉNDICE D	88
APÉNDICE E.....	91
APÉNDICE F	106
APÉNDICE G	108
BIBLIOGRAFÍA.....	109

ÍNDICE DE FIGURAS

Figura 1.1: Tipos de Sedimentación	2
Figura 1.2: Régimen de sedimentación en función del tipo de pulpa.....	3
Figura 2.2: Variación del contenido de sólidos y la conductividad para una pulpa de mineral	12
Figura 2.3: Barra multielectrodos	14
Figura 2.4: Línea de campo eléctrico, electrodo de 10mm diámetro, y diámetro del área de flujo 2.8 cm.....	16
Figura 2.5: Línea de campo eléctrico, electrodo de 20mm diámetro, y diámetro del área de flujo 3.9 cm.....	17
Figura 2.6: Línea de campo eléctrico, electrodo de 30mm diámetro, y diámetro del área de flujo 4.7 cm.....	17
Figura 2.7: Desviación de la constante de celda para tres dimensiones de electrodo.....	19
Figura 2.8: Electrodo de geometría plana (a) e inclinada (b).....	19
Figura 2.9: Constante de celda para geometría plana e inclinada.....	20
Figura 3.1: Diagrama físico de componentes del sensor.	25
Figura 3.2: <i>Software</i> usados en el manejo de señales	26
Figura 3.3: Dependencia de la constante de celda en función de la conductividad.....	34
Figura 5.1: Formas posibles de sedimentación.....	43
Figura 5.2: Diagrama del tanque fragmentado para lectura de perfiles de conductividad.....	44

Figura 5.3: Perfil de conductividad entregado por el simulador.	46
Figura 5.4: Simulación de Perfiles.....	48
Figura 5.5: Estructuras de red a evaluar.....	51
Figura 5.6: Tabla de errores de altura de lodos para el caso de caso sedimentación discreta	52
Figura 5.7: Tabla de errores de altura de lodos para el caso de caso sedimentación semi-discreta	53
Figura 5.8: Tabla de errores de altura de lodos para el caso de caso sedimentación semi-floculenta.....	53
Figura 5.9: Tabla de errores de altura de lodos para el caso de caso sedimentación floculenta.....	53
Figura 5.10: Tabla de errores de % de sólidos para el caso de caso sedimentación discreta	54
Figura 5.11: Tabla de errores de % de sólidos para el caso de caso sedimentación semi-discreta	54
Figura 5.12: Tabla de errores de % de sólidos para el caso de caso sedimentación semi-floculenta.....	54
Figura 5.13: Tabla de errores de % de sólidos para el caso de caso sedimentación floculenta.....	55
Figura 5.14: Error del porcentaje de sólido	58
Figura 5.15: Desviación estándar del error	58
Figura 5.16: Gráficos de regresión para 3 neuronas (dos repeticiones)	59
Figura 5.17: Gráficos de regresión para 5 neuronas (dos repeticiones)	59
Figura 5.18: Gráficos de regresión para 9 neuronas (dos repeticiones)	60
Figura 5.19: Error del porcentaje de sólido	60

Figura 5.20: Desviación estándar del error	61
Figura 5.21: Gráficos de regresión para 3 neuronas (dos repeticiones)	61
Figura 5.22: Gráficos de regresión para 5 neuronas (dos repeticiones)	62
Figura 5.23: Gráficos de regresión para 9 neuronas (dos repeticiones)	62
Figura 6.1: Sistema usado para medición de perfil de conductividad	64
Figura 6.2: Perfiles de conductividad obtenidos experimentalmente.....	65
Figura 6.3: Promedio de los errores de ajuste para cada repetición	67
Figura 6.4: Desv. estándar de los errores de ajuste para cada repetición	67
Figura 6.5: Regresión para 3 neuronas en capa oculta (repetición 19 y 14), para el 100% de los datos.....	68
Figura 6.6: Regresión para 3 neuronas en capa oculta (repetición 1 y 2), para los datos usado en validación (40%).....	69
Figura 6.7: Regresión para 3 neuronas en capa oculta (repetición 3 y 4) para los datos usado en validación (40%).....	70
Figura 6.8: Promedio de los errores de ajuste (modelo - datos experimentales) para cada repetición con 2 neuronas en capa oculta	71
Figura 6.9: Desviación estándar de los errores de ajuste (modelo - datos experimentales) para cada repetición con 2 neuronas en la capa oculta.....	72
Figura 6.10: Validación del modelo con 2 neuronas en capa oculta (repetición 1 y 2), para el 57% de los datos experimentales.....	73
Figura 6.11: Validación del modelo con 2 neuronas en capa oculta (repetición 3 y 4), para el 57% de los datos experimentales.....	74
Figura 6.12: Comparación de ajuste con 2 y 3 neuronas en capa oculta para el 100% de la data experimental.	74

ÍNDICE DE TABLAS

Tabla 2.1: Constante de celda teórica	18
Tabla 3.1: Tabla generada según procedimiento almacenado.	29
Tabla 3.2: Datos de calibración de la barra multielectrodos.....	31
Tabla 3.3: Datos para calibración, expresada en conductancia y conductividad.	32
Tabla 3.4: Datos de constante de calda para cada par de electrodos	33
Tabla 4.1: Problemas usados para la evaluación de algoritmos de entrenamiento rápido (Matlab <i>Neural Network Toolbox</i> , 2008).	39
Tabla 4.2: <i>Set</i> de datos para evaluación de modelos.....	40
Tabla 4.3: Error cuadrado medio en el entrenamiento de un modelo de red neuronal con algoritmos de Detención Temprana (ES) y Regularización Bayesiana (BR).	41
Tabla 5.1: Numero de parámetros mínimos para diferente número de neuronas en la capa oculta.	50
Tabla 5.2: Tabla de desviaciones promedio del error del nivel de lodos	55
Tabla 5.3: Tabla de desviaciones promedio del error del % de sólidos	55

RESUMEN

La investigación presenta los resultados de la aplicación de redes neuronales en un instrumento prototipo para espesadores en plantas concentradoras de minerales. El instrumento permite la predicción del nivel de lodos y concentración de sólidos, reduciendo las detenciones del equipo por sobre carga de material o pérdida de calidad en el agua recuperada.

Dada las características de la pulpa (distribución de tamaños, densidad, velocidades de sedimentación, química de la solución físico-química de partículas), la operación de los espesadores es compleja y presenta perfiles de concentración de sólido con formas variables. Esta condición limita técnicas convencionales de medición (sónico, presión, ópticos, radar) y no hace posible aplicar modelos determinísticos al perfil de sólidos, dada las altas no linealidades y variabilidad del sistema.

Para resolver esta problemática, se implementó un hardware para la medición de perfiles de conductividad y un modelo predictivo basado en redes neuronales. El *hardware* y *software*, basado en el modelo de Maxwell para dispersiones, permite medir el perfil de sólidos independientemente de las condiciones de operación.

Para el desarrollo del modelo predictivo se evaluaron redes con una capa oculta, variando el número de neuronas (4 estructuras) y comparando los algoritmos de Gradiente Conjugado y Levenberg-Marquardt, los que se

evaluaron con 4 tipos de curvas de sedimentación (discreta, semi-discreta, semi-floculenta, altamente floculenta) incorporando error experimental normal. La capacidad de predicción de la estructura seleccionada (9 entradas, una capa oculta con 2 neuronas y 2 salidas), fue validada usando pulpas con relave de Chuquicamata, en un equipo piloto de 50 litros con una barra de 10 electrodos de 60 cm de largo, y hardware diseñado y construido para esta aplicación, comunicado a través de interfaz con la base de datos que almacena la información entregada por el *hardware*, y usando pulpas con relave de Chuquicamata. Los resultados indican un error de predicción de 0.8 cm con una red de 26 parámetros.

Como conclusión se establece que el uso de redes neuronales con perfiles de conductividad, permite optimizar la medición altura de lodos y porcentaje de sólidos, lo que posibilita la transferencia de este instrumento a nivel industrial.

CAPÍTULO 1: INTRODUCCIÓN

El trabajo a realizar se contextualiza en la minería metálica específicamente en el procesamiento de mineral sulfurado, el cual incorpora en su proceso una etapa de separación sólido líquido (espesamiento), que por las características del sólido y condiciones de operación variable (floculantes, flujos, contenidos de sólidos), la respuesta operacional es compleja de predecir, lo que limita aplicar un control optimizante.

La metodología actual para calcular los parámetros operacionales (altura de lodo espesado, e inventario de sólidos) en espesadores industriales, se realiza a través de una calibración basada en el consumo eléctrico del equipo, lo cual arrastra error en la medición generando problemas operacionales como embancamientos, e impide la dosificación de reactivos que son necesarios en la operación de los espesadores.

Adicionalmente, para la medición de los parámetros operacionales de interés, los instrumentos existentes están limitados, principalmente, por la variabilidad de las condiciones de sedimentación, lo que genera perfiles de sólidos con interfases difusas y tipos de sedimentación altamente dependiente del consumo de reactivos, pasando de sedimentación discreta con una transición marcada entre el lodo y el agua clara, a una sedimentación sin transición, comportamiento que se representa en la Figura 1.1.

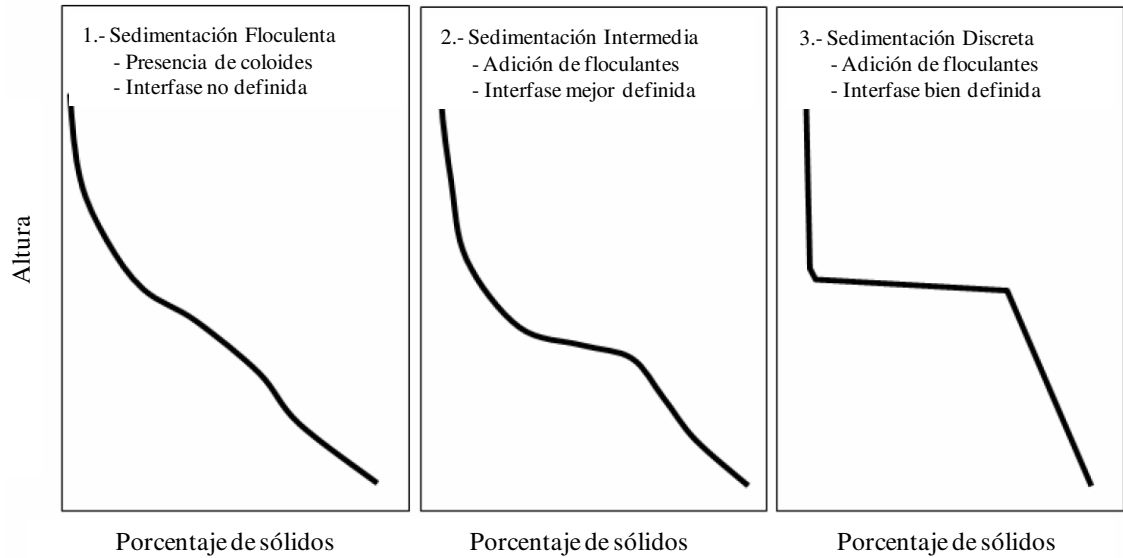


Figura 1.1: Tipos de Sedimentación.

La variación de perfiles de sedimentación se ve afectada por las condiciones de operación (flujo contenido de sólidos) y dosificación de reactivos o mineralogía que afectan el grado de adherencia de las partículas. Este comportamiento se ilustra en la Figura 1.2.

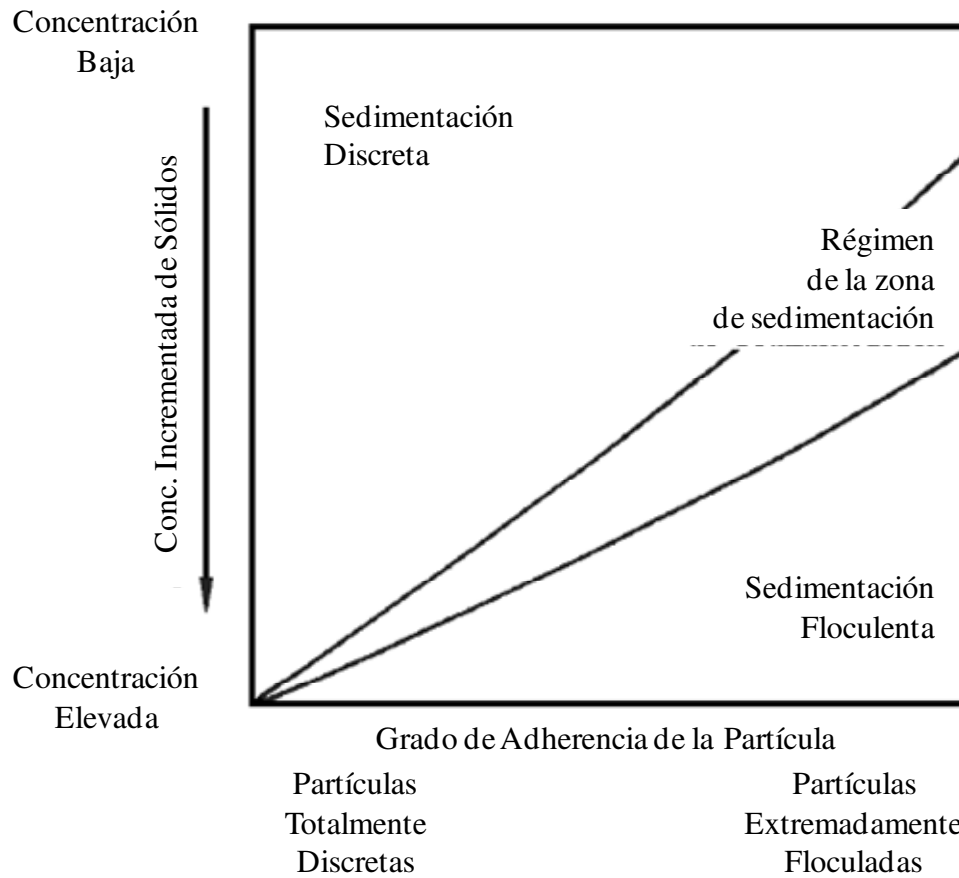


Figura 1.2: Régimen de sedimentación en función del tipo de pulpa (R. Perry, 1997).

Para la medición de los parámetros operacionales de interés, no existe instrumentación que mida simultáneamente el nivel de lodos y contenido de sólidos, los instrumentos disponibles en el mercado miden por separado estos parámetros y presentan limitaciones técnicas en su operación. Un análisis de los instrumentos disponibles para espesadores se describe en el Apéndice A.

Un instrumento prototipo, basado en perfiles de conductividad, con capacidades para medir simultáneamente nivel de lodos y contenido de sólidos fue desarrollado por Tavera y col. (1998). La instrumentación presentó una serie de complicaciones dada la poca robustez de la electrónica y la complejidad que presenta el trabajo en espesadores industriales (Gómez y col. 1998), esto implica una mantención constante de la instrumentación y la hace poco viable en su implementación.

Para dar respuesta a la necesidad de instrumentación de espesadores y mejorar la idea planteada por Tavera y col. (1998), se diseñó y mejoró un nuevo instrumento basado en perfiles de conductividad y electrónica inteligente para la lectura de conductividades. El equipo se materializó por un proyecto de Minera Escondida (4.4 millones), y se planteó el concepto de sensor inteligente, lo que fue acreditado como invención patentable por la oficina OTRI (2009) en un concurso de innovación en minería (premio 30 UF, para estudio del estado del arte).

Con el objeto de procesar la información de perfiles de conductividad con mayor robustez, se propone desarrollar un modelo predictivo de altura de lodos y concentración de sólidos, basado en redes neuronales, esto permitiría medir con mayor precisión y exactitud el perfil de sólidos, dada las capacidades de no linealidad que puede resolver una estructura de red neuronal, y dada las facilidades que presentan los algoritmos al optimizar los parámetros de ajuste. En particular el uso de mediciones de perfiles de conductividad para predecir interfases, usando redes neuronales ha

demostrado ser factible, por ejemplo en la detección de la interfase de espuma en columnas de flotación industrial (León y col. 1997).

En este contexto se propone desarrollar un instrumento prototipo para predecir el nivel de lodos y contenido de sólidos en espesadores, aplicando un modelo de redes neuronales, para el que se plantean los siguientes objetivos:

Objetivo general

Desarrollar un instrumento prototipo para predecir el nivel de lodos y contenido de sólidos en espesadores, aplicando un modelo de redes neuronales.

Objetivos específicos

- i. Diseñar y montar un sensor con electrónica robusta (cumplir norma IP64) para el registro en línea de perfiles axiales de conductividad en un espesador piloto de 50 litros.
- ii. Desarrollar y validar un modelo basado en redes neuronales artificiales para la predicción de altura de lodos y contenido de sólidos en forma experimental

- iii. Proponer una estrategia de entrenamiento y selección de estructura de redes neuronales, que permita cubrir los posibles escenarios de perfiles de sólidos en espesadores industriales.

- iv. Implementar un sistema de monitoreo piloto para espesadores con hardware inteligente de procesos.

CAPÍTULO 2: DISEÑO DEL SENSOR BASADO EN PERFILES DE CONDUCTIVIDAD

2.1 Definición de conductividad

La conductividad eléctrica es la propiedad de una sustancia de conducir corriente eléctrica. Se define por el símbolo k .

La conductividad es la constante de proporcionalidad en la ley de Ohm:

$$i = -k\Delta v \quad \text{ec. 2.1}$$

Donde i es la densidad de corriente (A/cm^2), Δv es el gradiente de potencial (volt/cm), y k es la conductividad (Ω^{-1}/cm). La conductividad también corresponde al recíproco de la resistividad (Ωcm) y la conductancia es el recíproco de la resistencia (Ω). En el sistema inglés la unidad de la conductancia es el Siemens (S) y $1S \equiv 1\Omega^{-1}$. Por tanto la unidad de conductividad es S/m (o mS/cm).

Para el caso del agua, la conductividad del agua potable es del orden de 500 $\mu S/cm$, mientras que para el caso del agua de mar esta alcanza 35.000 $\mu S/cm$. En el caso de las pulpas de minerales, la conductividad de la solución está en un rango de 5.000 a 15.000 $\mu S/cm$, y al agregar sólidos la

conductividad puede disminuir en $1.000 \mu\text{S}/\text{cm}$, lo que permite usar esta medición para establecer el contenido de sólidos (Cortés, 1998)

2.2 Medición de conductividad

Todas las sustancias conducen electricidad en algún grado. Algunos, como los metales, son buenos conductores y otros de pobre conducción (aislantes). A continuación se discute la conducción de energía eléctrica en una solución de electrolito acuoso.

La resistencia de una solución electrolítica no puede ser medida usando corriente directa, porque cambia la concentración del electrolito. La acumulación de electrolisis producto de los electrodos también altera la resistencia de la solución. En lugar de la corriente directa, una corriente alterna es usada para superar este efecto.

La medición de conductividad se realiza con dos placas paralelas donde se asume que el flujo de corriente es en ángulo recto, de potencial uniforme, y restringido por el área de las placas. Ver figura 2.1.

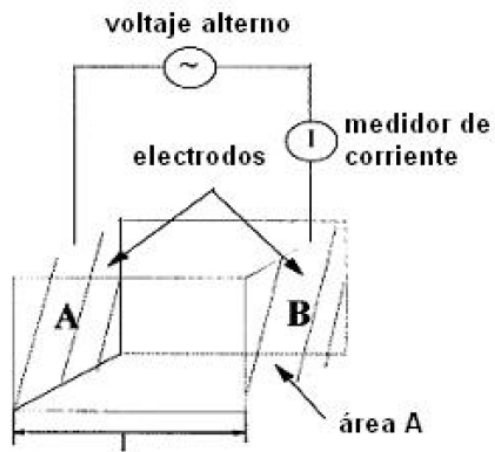


Figura 2.1: Celda de conductividad y circuito eléctrico para medir la conductividad de electrolitos.

Bajo supuestos descritos en párrafo anterior, la resistencia del electrolito está dada por:

$$R = \frac{\text{disminución de potencial}}{\text{corriente}} = \frac{v_A - v_B}{I} \quad \text{ec. 2.2}$$

Donde v_A y v_B son los potenciales en las placas de electrodos A y B respectivamente, e I es la corriente en el circuito eléctrico. En el caso de un conductor lineal, la densidad de corriente, i , en cualquier superficie equipotencial es constante. Por tanto,

$$I = \int_{A_{cell}} i dA_{cell} = i A_{cell} \quad \text{ec. 2.3}$$

$$v_A - v_B = -(v_B - v_A) = \int_a^b \Delta v dL = -\Delta v(b - a) = -\Delta v L \quad \text{ec. 2.4}$$

Donde A_{cell} es el área de la sección transversal de la celda, L es la longitud de la celda, y a y b son la posición de los electrodos A y B , respectivamente. Sustituyendo las ecuaciones 2.1, 2.3 y 2.4 en la ecuación 2.2, nos queda:

$$K = \frac{1}{R} = \frac{I}{v_A - v_B} = \frac{-i \left(\frac{A_{cell}}{L} \right)}{\Delta v} = k \frac{A_{cell}}{L} \quad \text{ec. 2.5}$$

Donde K es la conductancia del electrolito. En la ecuación 2.5 el término A_{cell}/L se refiere a la constante de celda, expresada en centímetro (cm). (Cortés 1998; Leiva 2006)

Como consecuencia, la medición de conductividad depende de la geometría del electrodo y el rango de medición del instrumento, por lo tanto el uso de electrodos de configuración variable permite medir conductividad en un rango mayor que el instrumento. Este aspecto es clave en el diseño posterior del equipo.

2.3 Modelo de Maxwell

El método de conductividades es una técnica que se usa para medir contenido volumétrico de una dispersión, como por ejemplo:

- contenido volumétrico de sólidos en una pulpa
- contenido volumétrico de gotas de orgánico en una solución
- contenido volumétrico de gas en pulpas o soluciones

Generalmente para el caso de las pulpas, la conductividad de la dispersión sólido líquido depende principalmente de la conductividad de la solución y el contenido volumétrico del sólido, y en la mayoría de los casos la conductividad del sólido no es influyente (partículas no conductoras).

El modelo Maxwell considera una fase líquida (o continua) que contiene pequeñas esferas (fase sólida o dispersa) de diferente conductividad. Asumiendo que la distancia entre las pequeñas esferas es lo suficientemente grande como para que su efecto en la perturbación de la trayectoria de la corriente pueda ser tomada como insignificante, la conductividad efectiva de la dispersión k_n está dada por:

$$k_n = k_l \frac{1 - \varepsilon_d}{1 + 0,5\varepsilon_d} \quad \text{ec. 2.6}$$

Donde k_l es la conductividad del líquido, y ε_d es la fracción en volumen del contenido de sólido de la dispersión.

La ecuación 2.6 también puede ser expresada como:

$$\varepsilon_d = \frac{1 - \frac{k_n}{k_l}}{1 + 0,5 \frac{k_n}{k_l}} \quad \text{ec. 2.7}$$

Para ilustrar la sensibilidad del modelo de maxwell, en la Figura 2.2 se grafica la fracción volumétrica de la pulpa y la variación de conductividad, en función del porcentaje de sólidos, para una pulpa típicamente encontrada en minería del cobre (densidad sólido seco 2.6 g/cc y conductividad de la solución de 10 mS/cm).

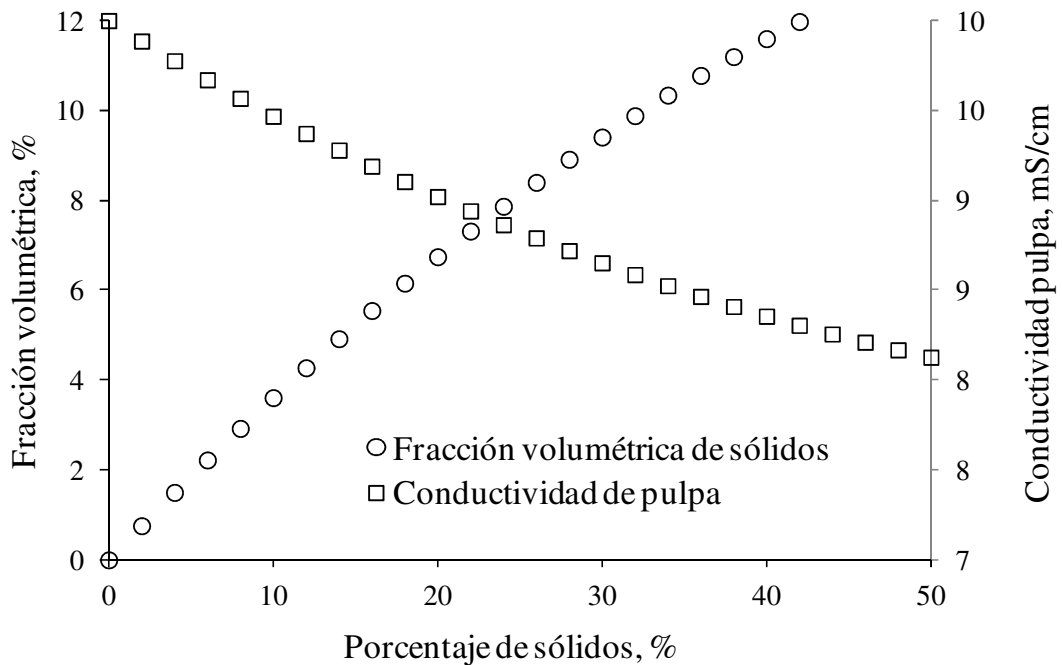


Figura 2.2: Variación del contenido de sólidos y la conductividad para una pulpa de mineral.

2.4 Criterios de diseño del sensor multielectrodos

Para medir en tiempo real la altura de lodos y porcentaje de sólidos, el instrumento requiere de una barra multielectrodos que esté sumergida al interior del espesador, y que capture la conductividad de la pulpa a distintas alturas.

Dadas las condiciones operacionales (humedad y abrasividad) en las que trabajan los espesadores, la barra multielectrodos debe tener en cuenta aspectos como la impermeabilidad del cableado (al interior de la barra multielectrodos) que transmite la señal al procesador (PLC). Además dada la característica abrasiva de la pulpa en que se va a sumergir la barra, ésta debe permitir la mantención o reemplazo de sus electrodos ante una eventual falla por desgaste de ellos.

2.4.1 Diseño de la barra multielectrodos

La barra consiste en un cilindro fabricado en HDP y sellado en su parte superior e inferior. Luego, a través de un orificio que cruza una parte del cilindro se acopla una base metálica (acero inoxidable) con hilo en su interior, ver Figura 2.3. Finalmente, la base metálica es donde va montado el electrodo que captura la señal de conductividad, y por cableado, se envía la señal al PLC. En la etapa de pruebas experimentales el diseño de la barra

nos permite trabajar con diferentes tipos de electrodos, y pensando en la versión industrial de la barra, su diseño facilita la mantención o el eventual reemplazo de electrodos.




Figura 2.3: Barra multielectrodos.

2.4.2 Diseño del electrodo

En la medición de conductividad, el área de flujo entre los electrodos y el espacio entre ellos, está ligado a una constante de celda (cc), constante que, en condiciones ideales, no afecta la medición de conductividad ya que su valor es igual a 1. En la realidad, la geometría del electrodo varía en función del entorno al que va a estar expuesto.

En nuestro caso, el electrodo va a medir conductividad en pulpa, y por tanto va a estar expuesto a fallas en la medición, ya sea por incrustamiento o desgaste del electrodo producto de las condiciones abrasivas del entorno.

Dada la condición mencionada, se elije trabajar con una geometría de electrodo tipo disco. Esta geometría nos proporciona un área, necesaria para la medición de conductividad, permite un fácil reemplazo de electrodos dañados (dada la sujeción a través de perno), y además, permite modificar la configuración del sensor, eliminando electrodos para adaptarse a medios con una alta conductividad.

Ya definida la geometría, se acota sus dimensiones. Para esto se debe conocer la relación entre el área del electrodo y la constante de celda. En este caso se evaluarán 3 discos de 10, 20 y 30 mm de diámetro, espaciados (de centro a centro) a 5 cm.

Para el caso del área de campo eléctrico (ec. 2.5), es necesario conocer las líneas de flujo, para ello se usa el software *Electric Field* versión 2.01, con el que se pueden simular campos eléctricos, variando geometrías. Los resultados se presentan en las Figuras 2.4 a la 2.5.

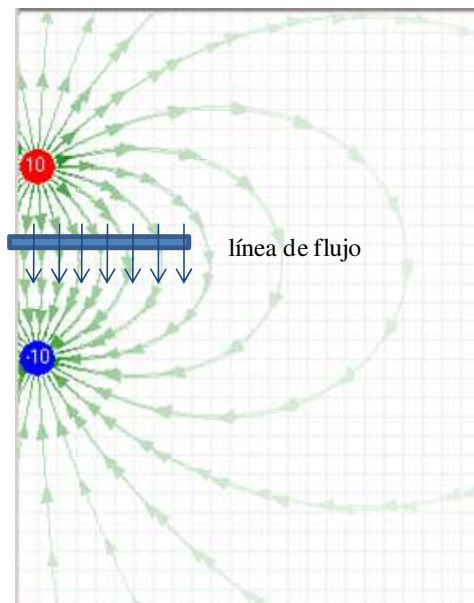


Figura 2.4: Línea de campo eléctrico, electrodo de 10mm diámetro, y 2.8 cm de diámetro del área de flujo.

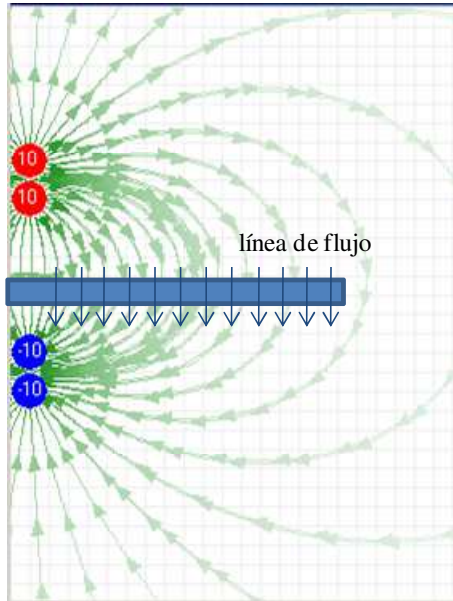


Figura 2.5: Línea de campo eléctrico, electrodo de 20 mm de diámetro, y 3.9 cm de diámetro del área de flujo.




Figura 2.6: Línea de campo eléctrico, electrodo de 30mm diámetro, y 4.7 cm de diámetro del área de flujo.

De estas figuras y considerando una reducción en la magnitud del campo eléctrico del 5%, se establecen los diámetros de un área de flujo teórica, en este caso 2.8, 3.9, 4.7 cm, para los discos de 10, 20 y 30 mm respectivamente. Los valores de constante de celda teórica (área de flujo sobre distancia entre discos), se presentan en tabla 2.1.

Diámetro del disco, (cm)	Diámetro del area de flujo, (cm)	Area de flujo, (cm)	Distancia entre discos, (cm)	Cte. de celda teórica
3	4.7	17.3	5	3.5
2	3.9	11.9	5	2.4
1	2.8	6.2	5	1.2

Tabla 2.1: Constante de celda teórica.

Para obtener los valores de constante de celda reales se requiere calibrar la barra de electrodos, usando una solución y midiendo su conductividad con un conductivímetro estándar. Los resultados experimentales para 12 niveles de conductividad, para los 3 diámetros de electrodos se presentan en la Figura 2.7.

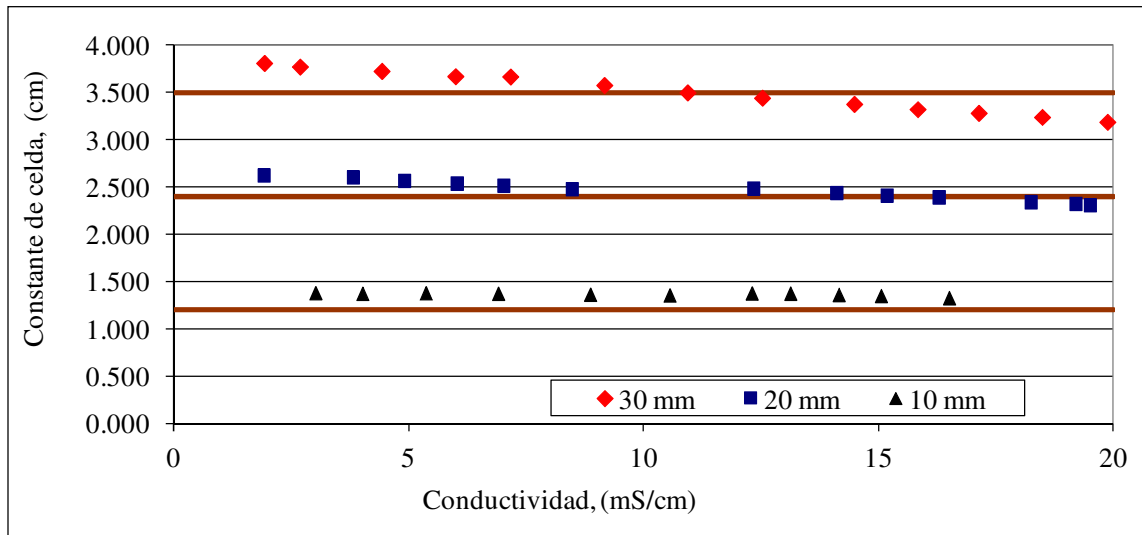


Figura 2.7: Desviación de la constante de celda para tres dimensiones de electrodo.

En esta figura se observa que la menor desviación, y sin bias, corresponde al electrodo de 20 mm.

Otro punto a evaluar en la geometría del electrodo es su inclinación, dado que idealmente la medición de conductividad se realiza entre dos placas paralelas. En este caso vamos a evaluar el comportamiento de la constante de celda entre un electrodo plano y un electrodo inclinado 15 grados respecto a la horizontal (ver Figura 2.8), ambos con 20 mm de diámetro.




Figura 2.8: Electrodo de geometría plana (a) e inclinada (b).

En la Figura 2.9 se muestra el comportamiento de la constante de celda entre una geometría plana y una geometría inclinada. Como se puede ver, no hay diferencia significativa en la constante de celda, por tanto podemos decir que la inclinación de 15 grados del electrodo no influye en la medición de conductividad.

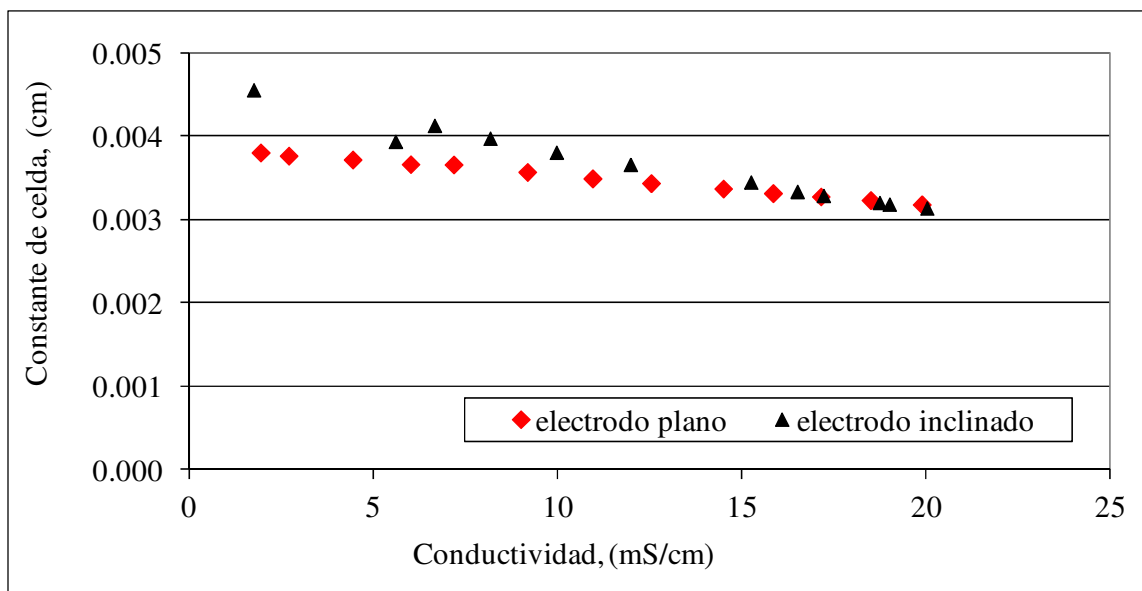


Figura 2.9: Constante de celda para geometría plana e inclinada.

Dado lo expuesto, el electrodo a usar en el sensor prototipo, para medición de altura de lodos e inventario de sólidos, corresponde a un disco plano de 20 mm de diámetro.

CAPÍTULO 3: DISEÑO, MONTAJE DEL HARDWARE DEL INSTRUMENTO Y DESARROLLO DE SOFTWARE DE CONECTIVIDAD.

3.1 Descripción del instrumento de medición

El instrumento lo componen diferentes componentes electrónicos los que en su conjunto son capaces de generar la información necesaria para el cálculo de altura de lodos y contenido de sólidos en un espesador piloto.

El flujo de información generada por el *hardware* es manejado por componentes lógicos que procesan la información, la almacenan y finalmente entregan información que facilita la operación en espesadores.

A continuación se explica en detalle el funcionamiento del *hardware* que captura las señales de conductividad, y la conectividad de software necesarios para coleccionar el perfil de conductividad del espesador piloto, y enviarlos a una base de datos.

Componentes del sistema

a.- Controlador Lógico Programable (PLC)

Corresponde a un dispositivo electrónico ampliamente usado en la automatización industrial, su función es monitorear y controlar maquinas y

procesos industriales. Hoy en día los PLC son capaces de mantener un control en las variables de proceso y pueden ser programados para cumplir tareas específicas como multiplexar una señal. El PLC utilizado para manejar la captura de señales de conductividad es un OPTO_22 modelo SNAP PAC R1.

b.- Conductivímetro

El conductivímetro tiene la función de cuantificar la capacidad del medio para conducir corriente eléctrica. En nuestro sistema utilizamos un conductivímetro Yokogawa (Mod. EXAxt450).

c.- Multiplexor

El concepto multiplexor corresponde a captar señales desde diferentes puntos a través de solo un instrumento que mide dicha señal. Para cumplir con la función indicada se requiere el uso de 10 relés (RC-HF41-24VDC) electromecánicos, los que son conectados al conductivímetro y al PLC, este último debe ser programado para mutiplexar la señal de conductividad usando los relés electromecánicos.

d.- Barra multielectrodos

Consiste en una sonda sumergible, la que a través de electrodos montados a lo largo de la barra miden conductividad en distintas alturas del medio donde esté sumergida. La versión prototipo posee un diseño que permite el reemplazo de electrodos de manera fácil y rápida, además nos da la opción de hacer test con diferentes geometrías de electrodos con distintos tamaños.

e.- Sistema de tanques (espesador piloto)

Para la simulación del espesador se usan 2 tanques los que están conectados por 2 bombas tipo peristálticas para el manejo de pulpa (mezcla sólido - líquido). Al igual que un espesador industrial, el espesador piloto es alimentado por una pulpa en la parte central del tanque, y sus descargas están en la parte superior con líquido claro y en la parte inferior con sólido decantado. Por regulación de flujos en bombas peristálticas el sistema permite variar la altura de lodos y el porcentaje de sólidos según se requiera, además, se tiene la opción de contrastar la información entregada por el sensor con información real a través de la toma de muestras en las distintas alturas del tanque y la medición de altura del lodo a través de visor acrílico.

3.2 Adquisición de datos

Para la captura en línea de perfiles de conductividad se requiere de componentes electrónicos programables, además requiere componentes lógicos de software, que son necesarios para realizar la captura de datos, historización, y posterior procesamiento de la información. Para un mejor entendimiento del sistema, la adquisición de datos se abordará explicando la conectividad de *hardware*, y de manera separada la lógica necesaria para obtener perfiles de conductividad en línea para almacenamiento en base de datos (SQL Server 2005).

3.2.1 Configuración del hardware

El hardware lo compone el PLC con el rack de módulos incorporado, un conductivímetro y un multiplexor. El PLC tiene la función de enviar una señal a un relé electromecánico para cerrar o abrir el circuito en la medición de conductividad. A su vez los relés electromecánicos cumplen la función de multiplexar la señal ya que a través de la abertura y cierre del circuito se encargan de direccionar la señal de conductividad en diferentes alturas del tanque piloto. Finalmente la lectura de conductividad es leída por el sensor de conductividades y su señal varía de posición según la secuencia programada en el PLC.

La Figura 3.1 muestra la conectividad del *hardware*, necesaria para la medición de conductividad en diferentes alturas de una barra multielectrodos montada en un tanque.

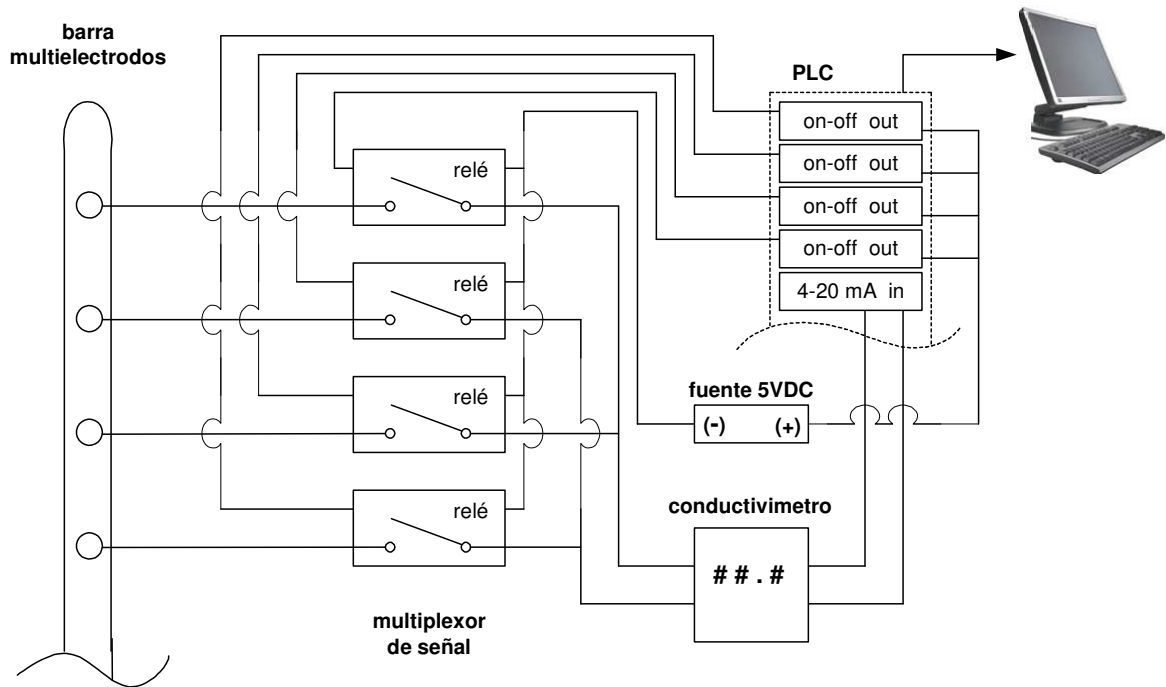


Figura 3.1: Diagrama físico de componentes del sensor.

3.2.2 Conectividad de software

Para comunicación del *hardware* es importante el uso de diferentes software que nos ayudan a manejar las señales enviadas por la instrumentación.

Siguiendo el flujo de datos tenemos el HMI (*human machine interfase*) de Opto_22 que recibe y ordena las señales capturadas por el instrumento (señal de estado y de conductividad), estas señales son recogidas por una interfaz Opto_DataLink (ver configuración en Apéndice B) la que se encarga de enviar la información a una base de datos donde finalmente se almacenan los perfiles de conductividad captados por la instrumentación.

La información es capturada y enviada en tiempo real a la base de datos, quedando disponible para su posterior procesamiento (ver cap. 3.2.3).

El uso de MATLAB se incluye dada su disponibilidad para lectura de datos desde diferentes fuentes, además esta herramienta nos permite programar aplicaciones y generar modelos de tipo predictivo como el de redes neuronales artificiales.

La Figura 3.2 muestra el manejo del flujo de información desde un punto de vista lógico:

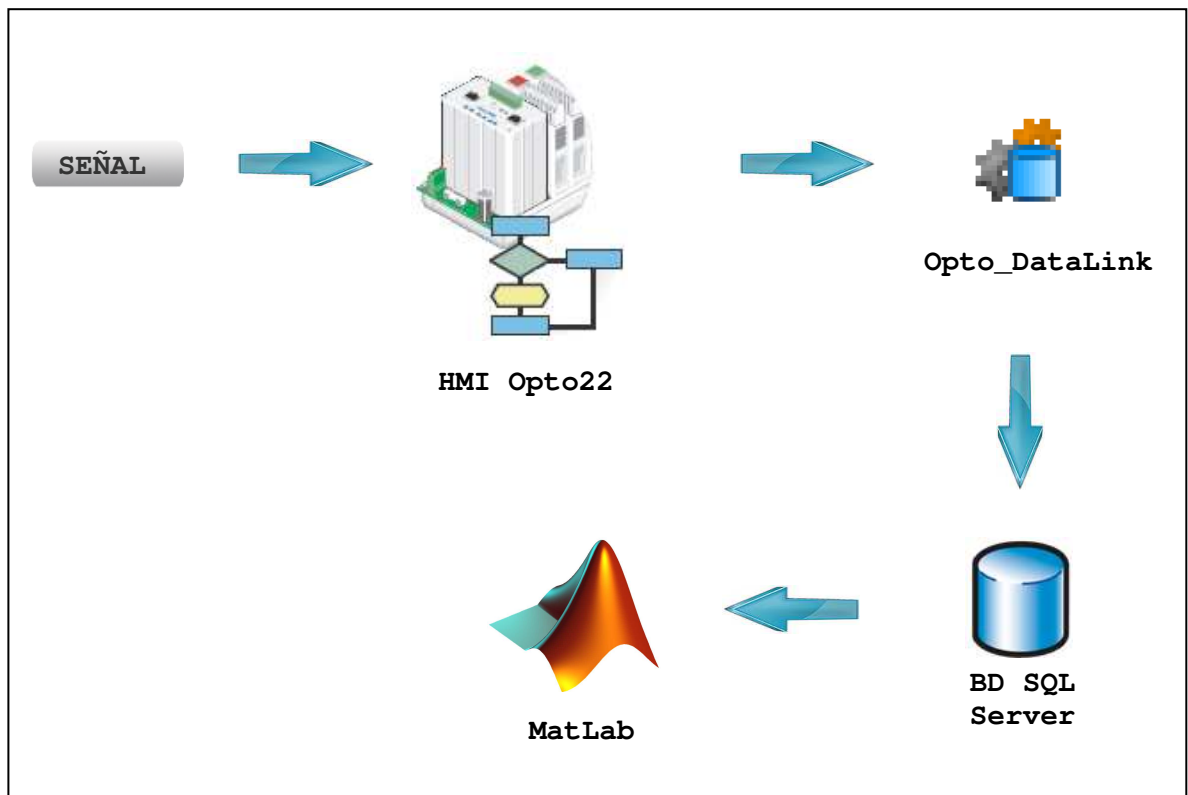


Figura 3.2: Software usados en el manejo de señales.

3.2.3 Programación para captura e historización de datos

En el caso del sensor de altura de lodos y porcentaje de sólidos para realizar un procedimiento de lectura automático y posterior historización de la información, previamente se debe trabajar con una programación (en el PLC) que captura la señal, esto nos permite generar patrones de lectura lo cual es útil al momento de ordenar la información e historizarla según sea nuestra necesidad.

La lectura de señales entregada por la instrumentación debe ser leída por un HMI, para el caso del PLC, el software usado es el *Pac Basic Control*, el cual lee la señal entregada por la instrumentación, además por programación en bloques es posible generar rutinas que realicen tareas específicas. En este caso el tipo de programación por bloques es una programación lineal cíclica que realiza secuencias de encendido y apagado que son útiles al momento de trabajar con múltiples señales.

La información proveniente de PLC y en general de cualquier sistema de control es información poco amigable y debe pasar por algún tipo de filtro que nos permita visualizar e interpretar los datos de mejor forma. Es por esto que para el caso de la información entregada por el sensor de altura y porcentaje de lodos se requiere de programación para realizar procedimientos de filtrado que elimina por ejemplo la información no numérica, datos repetidos y peaks en la data de entrada.

La importancia de la instrumentación radica en la entrega de parámetros operacionales en línea por tanto el procedimiento para procesar las señales de entrada debe ser también en tiempo real. Para lograr una disponibilidad de información en línea, las señales capturadas por el sensor se envían directamente a una base de datos, esto nos permite trabajar de manera rápida con grandes cantidades de información. La programación necesaria para consolidar la información de perfiles de conductividad, entregada por el PLC, es ejecutada por un procedimiento almacenado que ejecuta continuamente una tarea para el ordenamiento y limpieza de datos, quedando disponible la información de perfiles de conductividad en tiempo real.

Las opciones para lectura o cálculos que se requieran a partir de la información almacenada son variadas. Actualmente software de desarrollo como MATLAB y SPSS Clementine permiten una lectura en línea de información contenida en bases de datos. En Apéndice F se muestra un ejemplo para lectura de datos desde Matlab a una base de datos (SQL Server 2005). Esto nos entrega un potencial en el desarrollo de aplicaciones de tipo predictivas.

Como resultado, la programación del procedimiento almacenado para la historización y adquisición de datos en tiempo real, nos entrega información confiable que queda disponible para su uso al momento de ser procesada y almacenada en la base de datos. La Tabla 3.1 es una vista final de la información almacenada en la base de datos.

id	fecha	c1	c2	c3	c4	c5	c6	c7	c8	c9
20	12/02/2010 17:58:00	20,5200	20,5204	13,5724	6,3304	6,3260	6,3392	6,2860	6,2512	6,3324
21	12/02/2010 18:01:00	20,5196	20,5224	6,6360	6,3368	6,3300	6,3440	6,2996	6,2700	6,3444
22	12/02/2010 18:04:00	20,5184	20,5236	6,6316	6,3332	6,3364	6,3492	6,3100	6,2784	6,3508
23	12/02/2010 18:07:00	20,5188	20,5204	13,5788	6,3372	6,3404	6,3516	6,3176	6,2880	6,3508
24	12/02/2010 18:10:00	20,5224	20,5208	6,1928	5,9520	5,9464	5,9664	5,9304	5,8884	5,9508
25	12/02/2010 18:13:01	20,5192	20,5232	6,2008	5,9552	5,9544	5,9688	5,9356	5,9000	5,9576
26	12/02/2010 18:16:00	20,5208	20,5224	6,1928	5,9500	5,9496	5,9676	5,9356	5,9076	5,9692
27	12/02/2010 18:19:00	20,5180	20,5176	6,1956	5,9560	5,9532	5,9692	5,9356	5,9076	5,9656

Tabla 3.1: Tabla generada según procedimiento almacenado.

En el Apéndice C está el detalle de la programación usada en el procedimiento almacenado.

3.3 Calibración del sensor multielectrodos

Inicialmente la lectura del sensor corresponde a la señal de resistencia (ohm) que se genera entre electrodos, a partir de esta información podemos calcular de manera exacta la conductividad medida en un par de electrodos.

Los parámetros de medida que rigen la conductividad son la conductancia que corresponde al recíproco de la resistencia medida en la celda, y la constante de celda que está dada por las dimensiones de la geometría de los electrodos. El procedimiento de calibración es básicamente para obtener el valor de la constante de celda, ya que para la forma en que están dispuestos los electrodos y su tipo de geometría (electrodos tipo disco) es difícil obtener el valor a partir de sus dimensiones.

El procedimiento para calibrar la barra multielectrodos se realiza sumergiendo la barra multielectrodos en un medio líquido manteniendo una medición de resistencia con el conductímetro, en forma paralela con un conductímetro portátil (de laboratorio), cuya calibración se realiza a partir de solución patrón, se mide la conductividad de la solución donde está sumergida la barra multielectrodos. Para incrementar la conductividad del medio líquido se adicionan cantidades de sal a la solución (mezclado homogéneo), de esta forma se obtiene la medición de resistencia a distintas conductividades.

La información obtenida de la calibración de las nueve celdas se muestra en la siguiente tabla:

resistencia – ohm							conductividad
c3	c4	c5	c6	c7	c8	c9	mS/cm
119,38	105,33	104,99	105,21	103,85	102,64	104,92	1,85
62,48	55,32	55,14	55,19	54,24	53,58	54,91	3,62
32,93	29,57	29,33	29,38	28,78	28,33	34,51	7,15
27,44	24,42	24,39	24,60	24,18	23,76	24,51	8,68
21,47	19,11	19,11	19,28	18,92	17,92	18,43	11,35
16,88	15,01	15,03	15,22	14,97	14,77	15,21	14,76
15,14	13,58	13,58	14,05	13,87	13,67	14,05	16,67
12,95	11,68	11,67	11,78	11,60	11,39	11,75	19,69

Tabla 3.2: Datos de calibración de la barra multielectrodos.

La información de la Tabla 3.2 no muestra las celdas 1 y 2 ya que estas no quedan sumergidas en la solución de calibración dado que el tamaño del tanque en el que fue calibrada la barra multielectrodos no tiene el largo suficiente para dejar sumergidas todas las celdas.

Con la Tabla 3.2 podemos generar información de conductancia la que se relacionada con la resistencia. El cálculo corresponde al recíproco de la resistencia medida en ohms y la información se muestra en la Tabla 3.3.

conductancia - mS							Conductividad
c3	C4	c5	c6	c7	c8	c9	mS/cm
8,4	9,5	9,5	9,5	9,6	9,7	9,5	1,9
16,0	18,1	18,1	18,1	18,4	18,7	18,2	3,6
30,4	33,8	34,1	34,0	34,7	35,3	29,0	7,2
36,4	41,0	41,0	40,7	41,4	42,1	40,8	8,7
46,6	52,3	52,3	51,9	52,8	55,8	54,3	11,4
59,2	66,6	66,5	65,7	66,8	67,7	65,8	14,8
66,1	73,6	73,7	71,2	72,1	73,2	71,2	16,7
77,2	85,6	85,7	84,9	86,2	87,8	85,1	19,7

Tabla 3.3: Datos para calibración, expresada en conductancia y conductividad.

Luego con la conductancia y la conductividad podemos obtener el valor de la constante de celda para cada par de electrodos. Con la información obtenida de la calibración podemos hacer los cálculos en la data de entrada y obtener a partir de la resistencia la conductividad de la celda.

La Tabla 3.4 contiene los datos de la relación buscada de constante de celda en diferentes conductividades de la solución.

constante de celda – cc							conductividad
c3	c4	c5	c6	c7	c8	c9	mS/cm
4,5	5,1	5,1	5,1	5,2	5,3	5,1	1,9
4,4	5,0	5,0	5,0	5,1	5,2	5,0	3,6
4,2	4,7	4,8	4,8	4,9	4,9	4,1	7,2
4,2	4,7	4,7	4,7	4,8	4,8	4,7	8,7
4,1	4,6	4,6	4,6	4,7	4,9	4,8	11,4
4,0	4,5	4,5	4,5	4,5	4,6	4,5	14,8
4,0	4,4	4,4	4,3	4,3	4,4	4,3	16,7
3,9	4,3	4,4	4,3	4,4	4,5	4,3	19,7

Tabla 3.4: Datos de constante de calda para cada par de electrodos.

De esta forma se puede calibrar la barra de electrodos, en la que se indica una constante de celda para cada electrodo. La constante de celda varía entre los electrodos dado que hay distintos niveles de incrustación en los discos, o por pequeñas variaciones en la fabricación del electrodo. Por otra parte la constante de celda, también es función de la conductividad de la solución, esto es porque se cierran las líneas de campo al aumentar la conductividad de la solución. Este efecto se ilustra en la Figura 3.3, donde, a modo de ejemplo se grafican dos pares de electrodos.

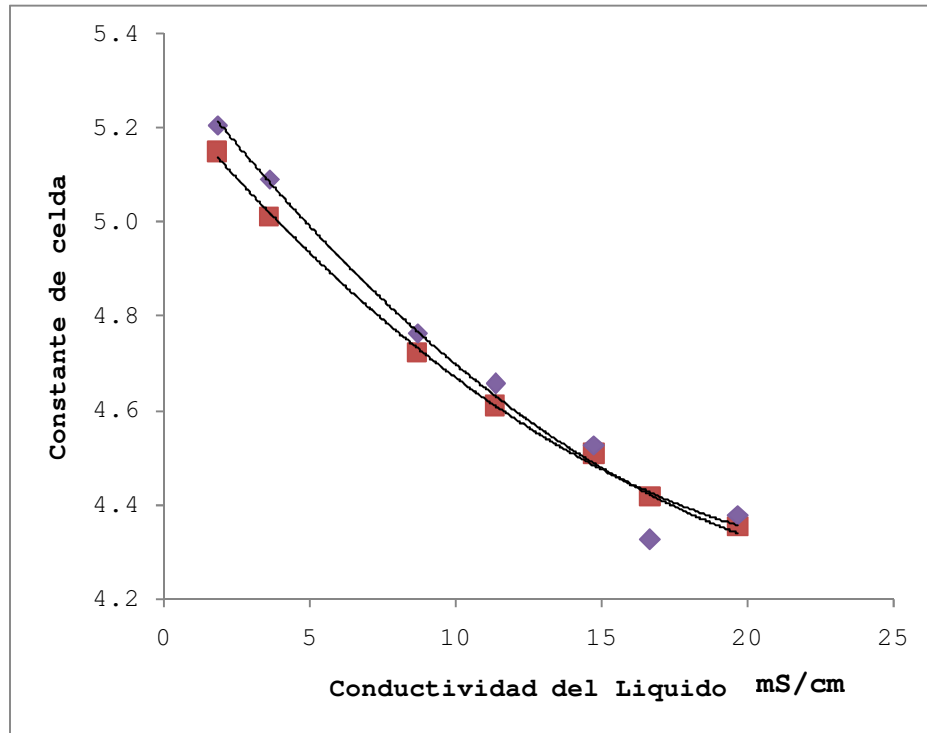


Figura 3.3: Dependencia de la constante de celda en función de la conductividad.

La variación de conductividad en la solución en una planta minera es gradual en el tiempo, debido por ejemplo a la acumulación de sales o efectos estacionales. Para el caso del modelo de Maxwell este efecto se compensa, dado que se usa el cociente de conductividades.

CAPÍTULO 4: ALGORITMOS USADOS EN REDES NEURONALES

4.1 Descripción de las redes neuronales

La disciplina que estudia las Redes Neuronales Artificiales corresponde a la Inteligencia Artificial Subsimbólica, que como estructura, parte de un sistema genérico que va adaptándose y construyéndose hasta formar por sí mismo un sistema capaz de resolver una problemática. La perspectiva Subsimbólica trata de estudiar los mecanismos físicos que nos capacitan como seres inteligentes. Desde este punto de vista la perspectiva Subsimbólica estudia los mecanismos del sistema nervioso del cerebro, así como su estructura, funcionamiento y características lógicas, con la intención de diseñar programas basados en dichas características que se adapten y generen sistemas capaces de resolver problemas (Isasi y Galván, 2004).

Esta característica hace de las redes neuronales una herramienta que puede ser aplicable a cualquier tipo de problemática, donde los modelos matemáticos no se ajustan a una solución con la precisión requerida.

Como se hace mención en la introducción, una de estas problemáticas se da en la etapa de espesado, en donde, dadas las características del sólido (tamaño de partícula, densidad de sólido, adherencia entre partículas) y variabilidad del proceso, el perfil axial de concentración de sólidos en el

espesador toma formas variables que no son representadas por modelos lineales.

En este contexto la generación de un modelo de Red Neuronal para predicción de variables como altura de lodos y contenido de sólidos puede enfrentarse como una problemática de aproximación de funciones, y como tal, aplica ser abordado por un modelo basado en redes neuronales.

Lo siguiente de este capítulo tiene como objetivo documentar el desempeño de los distintos algoritmos de retropropagación y proponer estructuras para ser evaluadas en la medición de altura de lodos y contenido de sólidos en espesadores.

4.2 Algoritmo de Retropropagación

El algoritmo de aprendizaje es el mecanismo mediante el cual se van adaptando y modificando todos los parámetros de la red. En el caso del perceptrón multicapa se trata de un algoritmo de aprendizaje supervisado, es decir, la modificación de los parámetros se realiza para que la salida de la red sea lo más próxima posible a la salida proporcionada por el supervisor o salida deseada. Por tanto, el aprendizaje del perceptrón multicapa es equivalente a encontrar un mínimo de la función error (Hilera y col., 1995).

Para llevar la función de error al mínimo, se requiere la presencia de funciones de activación no lineales, esto hace que la respuesta de la red sea no lineal respecto a los parámetros ajustables, por lo que el problema de la minimización del error es un problema no lineal, y como consecuencia, tienen que utilizarse técnicas de optimización no lineales para su resolución.

Una técnica corresponde a la retropropagación, en la cual los pesos de la red se mueven a lo largo del gradiente negativo de la función de error. El término de retropropagación se utiliza debido a la forma de implementar el método del gradiente en el perceptrón multicapa, pues el error cometido en la salida de la red es propagado hacia atrás, transformándolo en un error para cada una de las neuronas ocultas de la red (Isasi y Galván, 2004).

Los algoritmos de retropropagación de gradiente descendente son a menudo demasiado lentos en problemas prácticos, siendo ésta una desventaja al momento de implementar un modelo predictivo en tiempo real.

En la siguiente sección se analizan algoritmos de alto rendimiento que pueden converger diez y hasta cien veces más rápido que los algoritmos de gradiente descendente.

4.3 Entrenamiento Rápido

El algoritmo de entrenamiento rápido cae en dos categorías. La primera categoría utiliza técnicas heurísticas, las que se desarrollaron a partir de un análisis del desempeño del algoritmo de gradiente descendente. La segunda categoría de algoritmos rápidos utiliza técnicas de optimización numérica (Matlab *Neural Network Toolbox*, 2008).

Para la categoría de optimización numérica, en la herramienta *Neural Network Toolbox* de MATLAB se evalúa el desempeño de los siguientes algoritmos:

- Levenberg-Marquardt
- BFGS Quasi-Newton
- Resilient Backpropagation
- Scaled Conjugate Gradient
- Conjugate Gradient with Powell/Beale Restarts
- Fletcher-Powell Conjugate Gradient
- Polak-Ribière Conjugate Gradient
- One Step Secant
- Variable Learning Rate Backpropagation

Para esta evaluación se utilizan seis diferentes problemas, tres de ellos corresponden al reconocimiento de patrones y los otros corresponden a problemas de aproximación de funciones. De estos problemas, 2 se

construyen con datos simulados y los otros 4 con datos reales. La Tabla 4.1 muestra el detalle de los problemas usados:

Problema	Tipo de Problema	Estructura de la Red Neuronal
SIN	Aproximacion de Funciones	1-5-1
PARITY	Reconocimiento de Patrones	3-10-10-1
ENGINE	Aproximacion de Funciones	2-30-2
CANCER	Reconocimiento de Patrones	9-5-5-2
CHOLESTEROL	Aproximacion de Funciones	21-15-3
DIABETES	Reconocimiento de Patrones	8-15-15-2

Tabla 4.1: Problemas usados para la evaluación de algoritmos de entrenamiento rápido (Matlab *Neural Network Toolbox*, 2008).

Para los problemas de aproximación de funciones, el algoritmo de Levenberg-Marquardt y el algoritmo de Gradiente Conjugado Escalado tienen la convergencia más rápida, además en muchos de los casos el algoritmo de Levenberg-Marquardt obtiene un error menor que el de otros algoritmos testeados.

4.4 Mejorando la Generalización de la Red

Son variados los algoritmos usados para mejorar la generalización de un modelo de red neuronal, entre ellos la Detención Temprana y a la Regularización Automática son los de mejor generalización (Matlab *Neural Network Toolbox*, 2008).

Los algoritmos mencionados en el mejoramiento de la generalización de la red cumplen el mismo objetivo pero en la forma de trabajar son totalmente distintos. A modo de ejemplo, al entrenar una red neuronal con un conjunto de datos pequeño la Regularización Bayesiana provee una mejor generalización que la Detención Temprana, esto porque la Regularización Bayesiana no requiere de un conjunto de datos (del conjunto inicial) para la validación del modelo.

Para seleccionar el o los algoritmos de mejor generalización, la herramienta *Neural Network Toolbox*, Versión 6.0 de MATLAB, analiza 7 casos (ver Tabla 4.2), todos de diferentes tamaños y diferente número de campos, tanto en la capa de entrada como en la capa de salida, donde se evalúa el error cuadrado medio para los diferentes conjuntos de datos.

Nombre	Descripción	Datos
Ball	Sensor doble de posición de bola	67
Sin (5%N)	Función seno con 5% de error Gaussiano	41
Sin (2%N)	Función seno con 2% de error Gaussiano	41
Choles (all)	Mediciones de colesterol, todo el set de datos	264
Choles (1/2)	Mediciones de colesterol, 50% del set de datos	132
Engine (1/4)	Sensor de un motor, 25% del set de datos	1199
Engine (all)	Sensor de un motor, todo el set de datos	300

Tabla 4.2: Set de datos para evaluación de modelos

Los resultados de la evaluación se muestran en Tabla 4.3.

Metodo	Ball	Sin (5%N)	Sin (2%N)	Choles (all)	Choles (1/2)	Engine (1/4)	Engine (all)
ES	1.20E-01	1.70E-01	1.30E-01	1.20E-01	1.40E-01	1.90E-02	1.30E-02
BR	1.30E-03	3.00E-02	6.30E-03	1.20E-01	9.30E-02	4.70E-03	2.60E-03
ES/BR	92	5	4	1	1.5	5.7	21

Tabla 4.3: Error cuadrado medio en el entrenamiento de un modelo de red neuronal con algoritmos de Detención Temprana (ES) y Regularización Bayesiana (BR).

En la Tabla 4.3 se puede ver que en la mayoría de los casos, la Regularización Bayesiana se comporta mejor que la Detención Temprana. La mejora en la generalización de la red se hace más notoria cuando el conjunto de datos para entrenamiento es pequeño. Una de las desventajas del método de Regularización Bayesiana se focaliza en el tiempo de convergencia, el que generalmente es mayor que en la Detención Temprana.

De esta forma se concluye que las estructuras más apropiadas son:

Gradiente conjugado combinado con detención temprana y el de Levenberg-Marquardt combinado con regularización bayesiana automática.

Dada las estructuras propuestas, se requiere establecer el número de capas ocultas. Para esto se debe determinar experimentalmente el menor número de neuronas en la capa oculta para minimizar el error de ajuste al de un valor establecido. De esta se forma se obtiene un modelo con un mínimo de parámetros y se alcanza el error permisible.

CAPÍTULO 5: DESARROLLO DE ESTRATEGIA DE ENTRENAMIENTO PARA OPTIMIZAR LA RED A IMPLEMENTAR

5.1 Estrategia para el ajuste de la red

La búsqueda de un modelo de red neuronal que más se ajuste al proceso de sedimentación en estado estacionario, necesariamente requiere de un conjunto de datos iniciales para realizar la evaluación de los distintos algoritmos de red neuronal. Éste conjunto de datos para entrenamiento puede ser provisto por datos reales obtenidos del proceso. Considerando que para el caso de la sedimentación es posible encontrar al menos 4 tipos de sedimentación, ilustrados en Figura 5.1, que indica la altura de lodos y la concentración de sólidos.

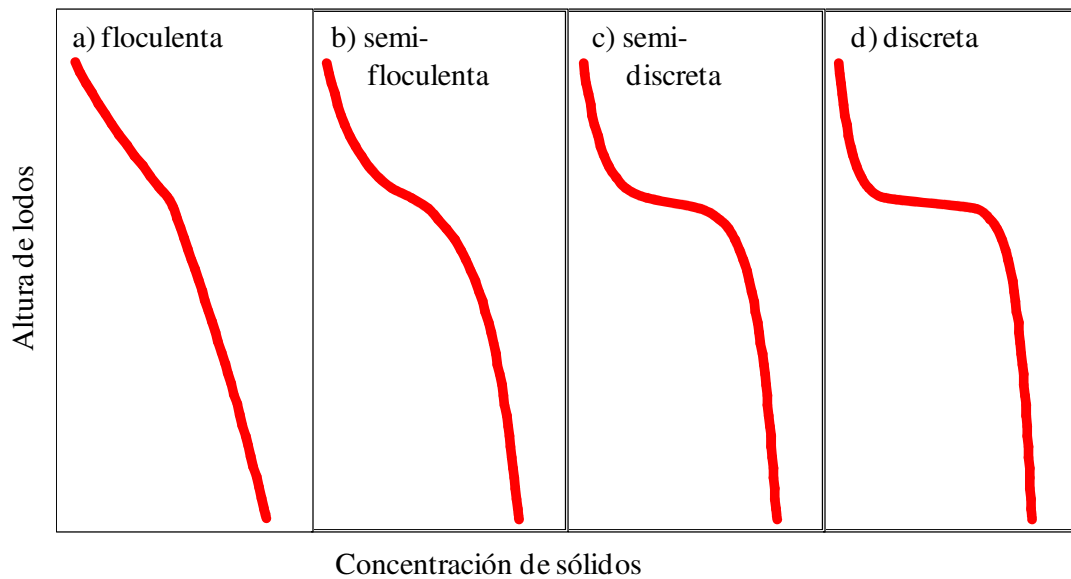


Figura 5.1: Formas posibles de sedimentación.

Considerando que la barra de electrodos del sensor prototipo es de 60 cm, el diseño del experimento propuesto es de usar intervalos de 5 cm, lo que para 10 electros espaciados a 5 cm, se obtienen 9 niveles de altura de lodos. Si se usan las 4 formas de sedimentación (Figura 5.1) para un solo contenido de sólidos, se requieren 180 experimentos (4 x 45, 4 formas de sedimentación y 45 niveles de sólido). Dada la complejidad que esto requiere, se propone como estrategia entrenar las estructuras de red neuronal con perfiles simulados, y de esta forma determinar el número de capas más apropiado, para posteriormente validar en forma experimental.

5.2 Modelado de curvas de sedimentación

Para simular el perfil de conductividades se usa la ecuación de Maxwell (ecuación 2.6), que permite calcular la conductividad a distintas alturas del tanque piloto y así obtener su perfil. Para el cálculo de conductividad es necesario conocer la fracción volumétrica de sólidos (ε_d) a distintas alturas del tanque. La fracción ε_d se representa en la siguiente figura:




Figura 5.2: Diagrama del tanque fragmentado para lectura de perfiles de conductividad.

Lo que sigue corresponde a las ecuaciones involucradas en la obtención del perfil de conductividades:

$$\varepsilon_d = \left(0,5 - \frac{\log(\beta + \sqrt{\beta^2 + 1})}{2 \times \alpha} \right) \times (\varepsilon_{d_max} - \varepsilon_{d_min}) + \varepsilon_{d_min} \quad \text{ec. 5.1}$$

Donde, α corresponde al tipo de sólido, ε_{d_min} y ε_{d_max} es la fracción de sólido mínima y máxima dentro del tanque. β se representa por ecuaciones distintas que dependen de la altura del nivel de lodos y la altura de medición.

Para altura de medición mayor o igual que la altura del nivel de lodos, β , está dada por la expresión:

$$\beta = \frac{(Exp(\alpha) - Exp(-\alpha)) \div 2 \times (H_{nivel_lodo} - H_{medición})}{H_{estanque} - H_{nivel_lodo}} \quad \text{ec. 5.2}$$

Para altura de electrodo menor que la altura del nivel de lodos, β , está dada por la expresión:

$$\beta = \frac{(Exp(\alpha) - Exp(-\alpha)) \div 2 \times (1 - H_{medición})}{H_{nivel_lodo}} \quad \text{ec. 5.3}$$

Donde, α corresponde al tipo de sólido, H_{nivel_lodo} es la altura del nivel de lodos, $H_{medición}$ es la altura de la medición y $H_{estanque}$ es la altura total del espesador, en nuestro caso del tanque piloto.

Luego reemplazando ecuación 5.2 o 5.3 (según corresponda) en ecuación 5.1, se obtiene la fracción volumétrica de sólidos.

Para el cálculo de conductividad se reemplaza la ecuación 5.1 en la ecuación 2.6 y sumando el error gaussiano obtenemos el valor de conductividad (k_n) en mS/cm para las distintas alturas del tanque piloto.

Un ejemplo de la curva simulada para perfiles de conductividad se ilustra en Figura 5.3




Figura 5.3: Perfil de conductividad entregado por el simulador.

En total se genera una base de datos para los 4 posibles perfiles de conductividad con 9 niveles de lodos, de esta forma se asegura la exactitud (modelo de sedimentación) y la precisión (variaciones de altura a intervalos de 5 cm). Ejemplos de perfiles simulados con variaciones de tipo de sólido sedimentado y distintas alturas se ilustran en la Figura 5.4.




Figura 5.1: Ejemplo de perfiles de conductividad (continua en la siguiente página)




Figura 5.4: Perfiles simulados, con alfa = 7 y altura de lodos = 55 (a), alfa = 7 y altura de lodos = 85 cm (b), alfa 1 y altura de lodos = 55 (c), alfa 5 y altura de lodos = 25 cm (d).

En Apéndice D se entregan los datos simulados de perfil de conductividad, nivel de lodos y contenido de sólido del espesor para los distintos tipos de sedimentación.

5.3 Obtención del número de neuronas en la capa oculta con datos simulados

En el modelamiento de una red neuronal de tres capas no existe ecuación para el cálculo del número de neuronas óptimo en la capa oculta. Si bien se

pueden generar algunas reglas para su cálculo, estas solo aplican al problema específico que modela la red pero no pueden ser tomadas como un criterio general para el diseño de estructuras de redes neuronales.

Dado que no hay una forma de calcular el óptimo de neuronas en la capa oculta si es posible determinar el número máximo de neuronas que pueden ser usados en esta capa, ya que existe una limitante que está en función de la cantidad de experimentos del conjunto de datos para entrenamiento de la red.

La ecuación 5.4 corresponde al cálculo del número de experimentos que se requieren para un cierto número de neuronas en la capa oculta (considera una neurona en la capa de salida):

$$n_{\text{param}} = n \times h + h \times s + h + s \quad \text{ec. 5.4}$$

Donde;

n = número de neuronas en la capa de entrada

h = numero de neuronas en la capa oculta

s = numero de neuronas en la capa de salida

La Tabla 5.1 presenta el cálculo del número de parámetros requeridos para diferente número de neuronas en la capa oculta:

h	nparam
2	26
3	38
4	50
5	62
6	74
7	86
8	98
9	110
10	122
11	134
12	146
13	158
14	170
15	182
16	194

Tabla 5.1: Numero de parámetros mínimos para diferente número de neuronas en la capa oculta.

Dada la tabla anterior el número máximo de neuronas en la capa oculta para un conjunto de datos de 44 experimentos corresponde a 4 neuronas (aproximadamente).

Por tanto los modelos de red neuronal a testear para el cálculo de altura de todos e inventario de sólidos corresponden a las siguientes estructuras:

Capa de Entrada: 9 neuronas en la capa de entrada, las que están dadas por el número de mediciones (9 mediciones) en el perfil de conductividades entregado por el hardware.

Capa Oculta: En la capa oculta es donde se van a evaluar 3 estructuras que corresponden a 2, 3, 4.

Capa de salida: El número de neuronas en la capa de salida está dada por el entregable, es decir, el contenido de sólidos y la altura de lodos del tanque (dos neuronas).

Dado lo anterior, se presentan las estructuras de red a ser evaluadas:

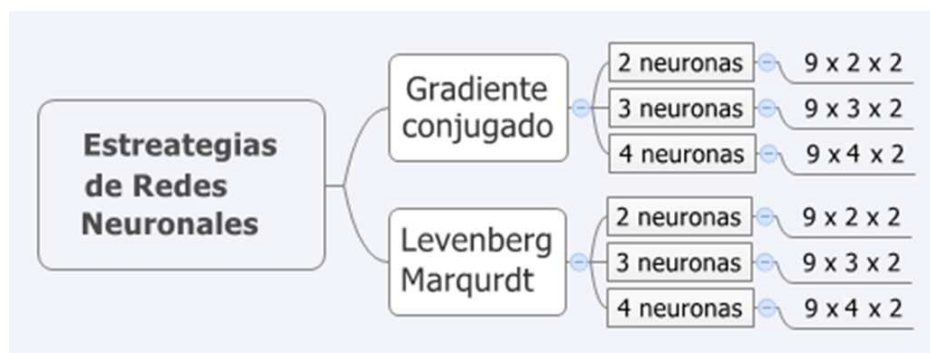


Figura 5.5: Estructuras de red a evaluar.

Consideraciones:

- Cada estructura de red neuronal se entrena por separado con cuatro conjuntos de datos que corresponden a sedimentación Floculenta (conjunto 1), sedimentación Semi-Floculenta (conjunto 2), sedimentación Semi-Discreta (Conjunto 3) y sedimentación Discreta (conjunto 4).
- Cada entrenamiento toma aleatoriamente un 70% del conjunto de datos para entrenamiento, un 15% para validación interna, y 15 % para evaluar el modelo.

- El entrenamiento se repite cinco veces
- La evaluación de los distintos algoritmos y estructuras de red neuronal se realizan en software Matlab (versión 7.6, modulo de redes neuronales).

A continuación se muestran las tablas con errores asociados a cada estructura de red neuronal asociada al conjunto de datos:

La nomenclatura del gráfico corresponde a:

“algoritmo” – “número de neuronas en la capa oculta”, donde el algoritmo SCG es el de gradiente conjugado escalado y LM Levenberg-Marquardt.




Figura 5.6: Tabla de errores de altura de lodos para el caso de caso sedimentación discreta.




Figura 5.7: Tabla de errores de altura de lodos para el caso de caso sedimentación semi-discreta.




Figura 5.8: Tabla de errores de altura de lodos para el caso de caso sedimentación semi-floculenta.




Figura 5.9: Tabla de errores de altura de lodos para el caso de caso sedimentación floculenta.




Figura 5.10: Tabla de errores de % de sólidos para el caso de caso sedimentación discreta.




Figura 5.11: Tabla de errores de % de sólidos para el caso de caso sedimentación semi-discreta.




Figura 5.12: Tabla de errores de % de sólidos para el caso de caso sedimentación semi-floculenta.




Figura 5.13: Tabla de errores de % de sólidos para el caso de caso sedimentación flocculenta.

Nivel de lodos	
Algoritmo	Promedio $desvest^2$
LM-3	2.2
LM-2	2.3
SCG-5	2.5
LM-5	2.9
SCG-2	3.3
SCG-3	3.5

Tabla 5.2: Tabla de desviaciones promedio del error del nivel de lodos.

Porcentaje de sólidos	
Algoritmo	Promedio $desvest^2$
LM-3	1.0
LM-5	1.1
SCG-3	1.2
LM-2	1.3
SCG-5	1.4
SCG-2	1.9

Tabla 5.3: Tabla de desviaciones promedio del error del % de sólidos.

De lo anterior podemos concluir que el modelo con mejor ajuste es el de Levenberg-Marquardt con 3 neuronas en la capa oculta, tanto para la altura de lodos como para el porcentaje de sólidos en el tanque.

Otra forma de ver los datos es trabajar un conjunto de datos conformado por los cuatro conjuntos de datos iniciales, es decir, datos simulados de la sedimentación discreta, semi-discreta, floculenta y semi-floculenta. Esto da la opción de trabajar con una capa oculta de mayor tamaño, lo que en nuestro caso para un conjunto de datos de 176 experimentos, donde el 70 % son para entrenamiento, se cuenta con un máximo de 123 experimentos, por tanto el máximo de neuronas en la capa oculta corresponde a 11 neuronas.

5.4 Ajuste de modelo generalizado para todos los tipos de curvas

Después de analizar estructuras de red neuronal más apropiadas a los distintos tipos de sedimentación, se obtiene un modelo óptimo para cada curva de sedimentación. Dado que en la práctica no es posible predecir el tipo de sedimentación, se requiere de un modelo generalizado. Para esto y dado que los resultados previos indican que en la mayoría de los casos el algoritmo de Levenberg-Marquardt, con 3 neuronas en la capa oculta presenta los menores errores, se utilizará este algoritmo, combinado con la regularización bayesiana automática para el modelo generalizado.

Como metodología se usará una base de datos para todos los casos de sedimentación, y se evaluarán 3, 5, 9 y 11 neuronas en la capa oculta, dado que en este caso se tienen simulado 176 perfiles. Esta estrategia permitirá visualizar si un aumento en redes neuronales mejora la predicción.

Para la optimización de redes neuronales se usa el 70% de los datos para entrenar, 15% para validación interna, y 15% de los datos para evaluar el modelo, estos últimos son independientes y no han sido usados en la optimización de la red.

El muestreo para entrenamiento, validación y evaluación se realiza en forma aleatoria, y para evaluar este muestreo se realizan 30 repeticiones.

Los resultados para un barrido de 2 a 11 neuronas en la capa interna con 30 repeticiones cada una se muestra en Figura 5.14, que presenta el error promedio de ajuste de los datos usados para evaluar (15% de la muestra), y sus respectivas mediciones.

Resultados para porcentaje de sólidos:

Nota, el error está en porcentaje de sólidos el que en espesadores de alta tasa alcanza un máximo de 80% de sólidos.




Figura 5.14: Error del porcentaje de sólido.

Para visualizar el grado dispersión de los datos también se presentan las desviaciones estándar de ajuste en Figura 5.15

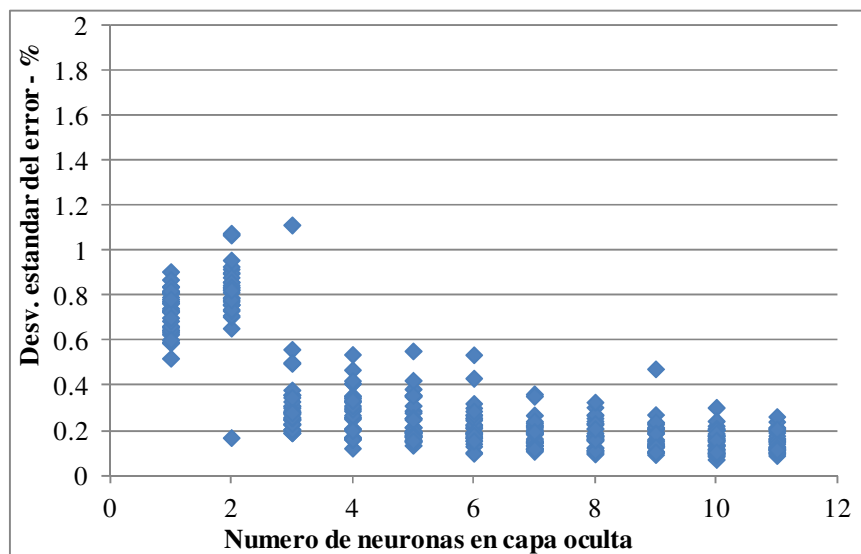


Figura 5.15: Desviación estándar del error.

Como ejemplo se presentan los gráficos de regresión para 3 neuronas y 2 repeticiones, y 5 y 9 neuronas respectivamente.

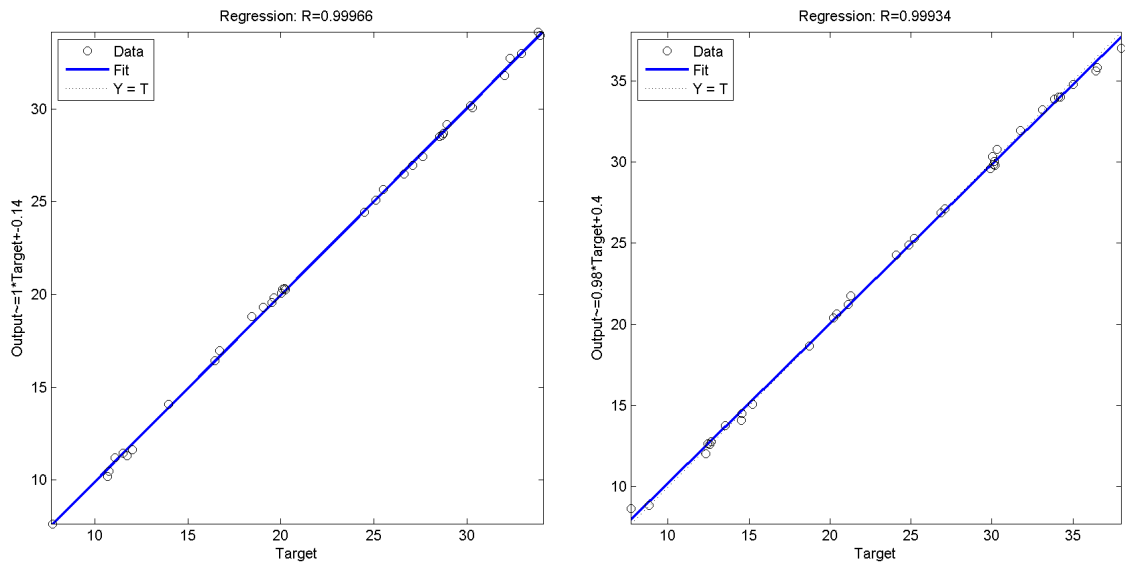


Figura 5.16: Gráficos de regresión para 3 neuronas (dos repeticiones).




Figura 5.17: Gráficos de regresión para 5 neuronas (dos repeticiones).




Figura 5.18: Gráficos de regresión para 9 neuronas (dos repeticiones).

Resultados para altura de lodos:




Figura 5.19: Error de la altura de lodos.

Para visualizar el grado de dispersión de los datos también se presentan las desviaciones estándar de ajuste en Figura 5.20




Figura 5.20: Desviación estándar del error.

Como ejemplo se presentan los gráficos de regresión para 3 neuronas y 2 repeticiones, y 5 y 9 neuronas respectivamente.




Figura 5.21: Gráficos de regresión para 3 neuronas (dos repeticiones).




Figura 5.22: Gráficos de regresión para 5 neuronas (dos repeticiones).




Figura 5.23: Gráficos de regresión para 9 neuronas (dos repeticiones).

Los histogramas de error asociados al ajuste tanto de altura de lodos como de porcentaje de sólidos se presentan comparados con el error del 100% de la muestra en apéndice E

La Figura 5.14 muestra el error asociado al porcentaje de sólido, el que varía entre ± 0.2 por ciento de sólidos. Además, la desviación estándar del error (Figura 5.15) del porcentaje de sólidos muestra una disminución al trabajar con 3 neuronas en la capa oculta, desviación que se mantiene constante para capas ocultas de mayor tamaño. Lo mencionado sumado a los coeficientes de correlación (Figura 5.16, 5.17 y 5.18) mayores a 0.999 nos permiten concluir que el número óptimo de neuronas en la capa oculta para el ajuste del porcentaje de sólidos es de 3 neuronas.

Para la altura de lodos vemos que el error del modelo está entre ± 0.8 cm. La gráfica de desviaciones estándar del error de la altura de lodos muestra una tendencia a la baja al aumentar el número de neuronas en la capa oculta, desviación que aumenta al superar las 7 neuronas. Dado que la variación de las desviaciones estándar no presenta mayores diferencias, y que los coeficientes de correlación son mayores a 0.99, se concluye que para el ajuste de la altura de lodos el tamaño óptimo de la capa oculta está entre 2 y 3 neuronas

CAPÍTULO 6: VALIDACIÓN EXPERIMENTAL CON RELAVES CHUQUICAMATA

Para la validación experimental del instrumento se trabaja con un equipo piloto de 50 litros, el que es cargado con relave de Chuquicamata para simular las condiciones reales de operación de un espesador industrial. La electrónica del sensor está conectada a una barra de 10 electrodos (para captura del perfil de sólidos) y de 60 cm de largo. En Figura 6.1 se muestra el sistema usado para medición de altura de lodos y contenido de sólidos en su versión prototipo.




Figura 6.1: Sistema usado para medición de perfil de conductividad.

En el equipo se registran perfiles de conductividad (9 puntos), y se lee desde una mirilla el nivel de interfase. Para la fase de validación solo se considera la altura de lodos a un porcentaje de sólidos fijo, no obstante la estructura de red permite la predicción de ambos parámetros. Como resultado experimental se obtienen un total de 71 perfiles (disponibles en Apéndice G). En la Figura 6.2 se presentan algunos de los perfiles obtenidos experimentalmente. De la figura se observan dos puntos de inflexión, el superior correspondiente a la línea de lodos o interfase agua clara pulpa, y la segunda inflexión correspondiente a la línea de compactación o consolidación de sólidos. Esta característica hace complejo diferenciar los puntos de inflexión, siendo necesario usar modelos más complejos, como el de redes neuronales.




Figura 6.2: Ejemplo de perfiles de conductividad obtenidos experimentalmente.

A partir de estos perfiles y la arquitectura de red seleccionada en el capítulo anterior (algoritmo Levenberg-Marquardt optimizado con método bayesiano con 3 neuronas en capa oculta), se realizan las calibraciones de la red neuronal, a fin reducir el error en la predicción y minimizar el número de parámetros requeridos.

6.1 Validación y calibración de la red neuronal con 3 neuronas en capa oculta

Se calibra la estructura de red con 1 capa oculta con 3 neuronas, con función de transferencia sigmoideal. Dado que el número de datos experimentales es 71 puntos (total de perfiles de conductividad) y para minimizar el número de datos de entrenamiento, se usa el 60% de los datos para el ajuste o calibración (55% entrenamiento + 5% validación interna) y el 40% de los datos experimentales para la validación independiente. En este caso se usan 39 *set* de datos para una estructura de red con 38 parámetros. Dado que en el ajuste de parámetros de la red neuronal se seleccionan aleatoriamente los datos para entrenamiento y los datos para testeo, es necesario repetir el procesos de entrenamiento para obtener la significancia estadística del ajuste y calcular los errores de ajuste. En este caso se realizan 30 entrenamientos o repeticiones, donde el error promedio de ajuste es graficado para cada una de las repeticiones (Figura 6.3). Adicionalmente, y para establecer el nivel de dispersión de errores se grafica la desviación estándar (Figura 6.4).




Figura 6.3: Promedio de los errores de ajuste (modelo - datos experimentales) para cada repetición.

De las Figuras 6.3 y 6.4 se concluye que es posible ajustar con redes neuronales la altura de lodos, a partir de perfiles de conductividad en forma consistente, además se mantienen los errores de ajuste, con un máximo de dispersión de 0.8 cm (dos veces la desviación estándar máxima).




Figura 6.4: Desviación estándar de los errores de ajuste (modelo - datos experimental) para cada repetición.

Como resultado de este ajuste, se presenta la regresión entre datos experimentales y las predicciones del modelo neuronal, en este caso 3 capas ocultas (Figura 6.5), para el 100% de los datos (incluye entrenamiento 55%, validación interna 5% y 40% validación con datos independientes de la optimización de la red). De la Figura 6.5 (replica 14 y 19), se observa un alto nivel de correlación (sobre 0.999) y un sesgo bajo (bajo 0.03 cm). Se observa un agrupamiento de datos para niveles de interfase bajos (bajo 28 cm de lodo), esto debido a que por condición de operación se alcanza la compactación de lodo a esa altura más rápidamente. No obstante lo anterior, datos experimentales cubre el rango completo del equipo piloto (25 a 45 cm).

Para el caso de la validación se usa el 40% de los datos restantes, y los resultados del ajuste se presentan en Figura 6.6.




Figura 6.5: Regresión para 3 neuronas en capa oculta (repetición 19 y 14), para el 100% de los datos.




Figura 6.6: Regresión para 3 neuronas en capa oculta (repetición 1 y 2), para los datos usado en validación (40%).

De la Figura 6.6, se observa también un alto grado de correlación entre el modelo ajustado y los datos experimentales. Adicionalmente el muestreo aleatorio de de datos mantiene el rango completo del experimento (25 a 45 cm de lodos), condición que se mantiene para todas las repeticiones. Un ejemplo adicional de esto se ilustra en Figura 6.7




Figura 6.7: Regresión para 3 neuronas en capa oculta (repetición 3 y 4) para los datos usado en validación (40%).

Para el caso de este experimento con 71 datos experimentales y una red con 9 entradas, 2 salidas y 3 neuronas en la capa oculta, se requiere 38 parámetros, lo que requiere mayor número de datos de entrenamiento, y en este caso restringe a 40% a los datos de validación. Considerando la estructura de red, para el caso del nivel presenta errores bajos para 2 y 3 neuronas (Figura 5.20), a continuación se analiza el caso de reducir a 2 neuronas la capa interna (oculta), y así validar con un peso los datos experimentales.

6.2 Validación y calibración de la red neuronal con 2 neuronas en capa oculta

Al usar una arquitectura 9x2x2, se requiere 26 parámetros y por tanto el número de datos experimentales se reduce a 27, con esto el porcentaje de datos que puede ser usado en la validación alcanza un 57%, lo que da mayor validez al modelo, sin embargo el costo es reducir la precisión del ajuste.

Al analizar los resultados del ajuste para 30 repeticiones, se observan que los errores promedio (Figura 6.8), están en un rango ± 0.2 cm, al igual que el caso 3 neuronas, con un solo caso sobre este rango, por tanto no hay diferencias significativas en el error promedio por ajuste (Figura 6.8).




Figura 6.8: Promedio de los errores de ajuste (modelo - datos experimentales) para cada repetición con 2 neuronas en capa oculta.

Del mismo modo al graficar la desviación estándar del ajuste para cada repetición (Figura 6.9), se observa un caso puntual sobre 0.6, y en general desviaciones del orden 0.2 a 0.3 cm. Como consecuencia no se observan desviaciones significativas al usar 2 neuronas, lo que es consistente con el análisis de data simulada que compara la desviación estándar del ajuste con el número de neuronas en capa oculta (Figura 5.20).




Figura 6.9: Desviación estándar de los errores de ajuste (modelo - datos experimentales) para cada repetición con 2 neuronas en la capa oculta.

Los resultados de ajuste para el caso de la validación (57% de los datos) se presentan en Figura 6.10.




Figura 6.10: Validación del modelo con 2 neuronas en capa oculta (repetición 1 y 2), para el 57% de los datos experimentales.

De la Figura 6.10 y las repeticiones restantes, se observa un alto nivel de ajuste, con correlaciones dato experimental/modelo sobre 0.999 y sesgos despreciables. Otro ejemplo se presenta en la Figura 6.11, donde se observa alto nivel de ajuste, para el rango completo del experimento.




Figura 6.11: Validación del modelo con 2 neuronas en capa oculta (repetición 3 y 4), para el 57% de los datos experimentales.

Finalmente, se compara la predicción de la red neuronal, para el caso de 2 y 3 neuronas en capas oculta (Figura 6.12)




Figura 6.12: Comparación de ajuste con 2 y 3 neuronas en capa oculta para el 100% de la data experimental.

De la Figura 6.12, se observan diferencias no significativas en el ajuste, con pérdidas de linealidad en los niveles bajo 30 cm. Esto permite usar un modelo con menor número de parámetros (26) y reducir a 27 perfiles el entrenamiento y validar con 40 perfiles independientes del entrenamiento, confiando mayor robustez a la estrategia propuesta.

De esta sección se concluye, que la validación con datos experimentales para una red 9x3x2 (9 entradas, 3 neuronas en capa interna y 2 salidas) presenta errores inferiores 0.6 cm (con 95% de confiabilidad). Por otra parte la reducción de neuronas en la capa oculta de 3 a 2 no presenta diferencias significativas. Como consecuencia, se obtiene un modelo parsimonioso, permitiendo usar más datos experimentales en la validación y por tanto facilitando la implementación a escala industrial.

CAPÍTULO 7: CONCLUSIONES Y TRABAJO FUTURO

7.1 Conclusiones

- El diseño y evaluación experimental de un instrumento de medición de altura de lodos y contenido de sólidos para espesadores industriales, con *hardware* para la medición de perfiles de conductividad y *software* de monitoreo conectado en tiempo real a un modelo de redes neuronales, demostró ser efectivo y robusto con un error de predicción de 1.6%.
- La estrategia de entrenamiento de redes neuronales, partiendo con datos simulados que cubren todos los escenarios posibles de las variables de operación, demostró ser eficiente para seleccionar la estructura de la red neuronal y el algoritmo de ajuste de parámetros de la red, permitiendo implementar una red parsimoniosa (26 parámetros), para una arquitectura 9x2x2.
- El software de conectividad desarrollado (control de hardware, comunicación OPC, base de dato relacional, ODBC para conexión Matlab a la base de dato), permite el monitoreo en línea y ajuste o calibración de parámetros con información histórica, facilitando la implementación de la tecnología a escala industrial.

- El hardware diseñado e implementado, permitió reproducir perfiles industriales en forma controlada y con medición independiente del nivel (visual), con lo que se aseguró confiabilidad de la información recopilada y posteriormente usada para validar la estructura de red seleccionada.

7.2 Trabajo Futuro

Si bien se valida a nivel piloto el concepto de un instrumento basado en un modelo de redes neuronales para predicción de altura de lodos y contenido de sólidos, se debe tener una validación en planta. Esta validación es fundamental al momento de comercializar el instrumento.

GLOSARIO Y ABREVIATURAS

BR	Regularización bayesiana
CC	Constante de celda
ES	Detención temprana
Espesador	Equipo de separación continua de sólido-líquido
Floculo	Por adición de sustancias denominadas floculantes, se aglutina el sólido y genera el floculo
HDP	<i>High density polyethylene</i>
HMI	Interfase humano maquina
IA	Inteligencia artificial
ODBC	<i>Open data base connectivity</i>
P	Proporcional
PI	Proporcional, integral
PID	Proporcional, integral, derivativo
PLC	Procesador lógico programable
Pulpa	Mezcla sólido líquido con contenido de mineral objetivo
Relave	Desecho o subproducto del proceso de concentración de minerales
SQL	Lenguaje de consulta estructurada

APÉNDICE A

La tabla muestra un análisis con la instrumentación disponible en el mercado para medición de altura de lodos y contenido de sólidos en espesadores industriales.

	Lectura de nivel	lectura porcentaje de sólidos	Descripción	Ventajas	Desventajas
sensor de perfiles de conductividad	X	X	Múltiples celdas capturan el perfil de conductividad del espesador	Calcula simultáneamente altura de lodos y contenido de sólido	Electrónica poco robusta <hr/> Requiere personal capacitado en su operación normal
sensor de turbiedad	X		Sensor de turbidez mide la absorbancia	Sensor tiene buenos resultados en líquidos claros	Requiere mantención frecuente especialmente en turbiedades disímiles como son los espesadores industriales.
sensor de ultrasonido	X		Principio de lectura se basa en la velocidad de reflexión del ultrasonido	indirecto	pierde precisión con línea de lodos poco definida
sensor de radioactividad		X	Para obtención de contenido de sólido se monitorea la variación de densidad de sólido	no tiene partes mecánicas	La adición de floculante genera error en la medición. <hr/> El ruido en la señal produce una lectura falsa o distorsión del resultado obtenido.

sensor óptico	X		El sólido es sensado y la señal es enviada por fibra a una locación remota donde se decodifica la señal	en línea	Tiene una limitación en el tiempo de respuesta. Muchas veces es muy tarde para hacer los ajustes necesarios y se pierde sólido por rebose.
---------------	----------	--	---	----------	--

APÉNDICE B

Configuración de interfaz Opto_DataLink para adquisición de datos.

Configure newLink

Data comes from a

Data items to scan:

[CONT]Ipltcp:146.83.115.77:22001]CTRLR:Time	Edit...	Delete
[CONT]Ipltcp:146.83.115.77:22001]CTRLR:Date	Edit...	Delete
[MMIO]Ipltcp:146.83.115.77:2001]EU[45]	Edit...	Delete
[MMIO]Ipltcp:146.83.115.77:2001]STATE[0]	Edit...	Delete
[MMIO]Ipltcp:146.83.115.77:2001]STATE[1]	Edit...	Delete
[MMIO]Ipltcp:146.83.115.77:2001]STATE[2]	Edit...	Delete
[MMIO]Ipltcp:146.83.115.77:2001]STATE[3]	Edit...	Delete
[MMIO]Ipltcp:146.83.115.77:2001]STATE[4]	Edit...	Delete
[MMIO]Ipltcp:146.83.115.77:2001]STATE[5]	Edit...	Delete
[MMIO]Ipltcp:146.83.115.77:2001]STATE[6]	Edit...	Delete
[MMIO]Ipltcp:146.83.115.77:2001]STATE[7]	Edit...	Delete
[MMIO]Ipltcp:146.83.115.77:2001]STATE[8]	Edit...	Delete
[MMIO]Ipltcp:146.83.115.77:2001]STATE[9]	Edit...	Delete

Scanner Location: Details...

and goes to a

Database Product:

Database Properties

Server Location:

Database Name:

User Login

Username:

Password:

Windows Security

Data Source Name

DSN:

Table name:

Database Columns:

hora	Delete
fecha	Delete
conduc	Delete
elec_11	Delete
elec_12	Delete
elec_13	Delete
elec_14	Delete
elec_21	Delete
elec_22	Delete
elec_23	Delete
elec_24	Delete
elec_31	Delete
elec_32	Delete

when

Interval: Hours, Minutes, Seconds, 00 Milliseconds

depending on

Data will always flow. Choose a different condition to refine your data exchanges.

APÉNDICE C

Procedimiento almacenado en BD:

```
set ANSI_NULLS ON
set QUOTED_IDENTIFIER ON
GO

ALTER PROCEDURE [dbo].[cargar_perfil]
AS
SET DATEFORMAT dmy
declare @SQL as Varchar(max)

Set @SQL='

insert into table_2 (fecha, c1, c2, c3, c4, c5, c6, c7, c8, c9)

select Convert(varchar,GetDate(), 103) +' +Convert(varchar,GetDate(), 108) as fecha,
        cel1, cel2, cel3, cel4, cel5, cel6, cel7, cel8, cel9

from (

select sum(cel1) as cel1,
       sum(cel2) as cel2,
       sum(cel3) as cel3,
       sum(cel4) as cel4,
       sum(cel5) as cel5,
       sum(cel6) as cel6,
       sum(cel7) as cel7,
       sum(cel8) as cel8,
       sum(cel9) as cel9

from (

select avg(cel1) as cel1,
       avg(cel2) as cel2,
       avg(cel3) as cel3,
       avg(cel4) as cel4,
       avg(cel5) as cel5,
       avg(cel6) as cel6,
       avg(cel7) as cel7,
       avg(cel8) as cel8,
       avg(cel9) as cel9

from (
select top 2 *
from (
select top 45 *
from (
select fecha_hora, convert(varchar,flag) as flag,
       case when flag = '1' then conduc else '0' end cel1,
       case when flag = '2' then conduc else '0' end cel2,
       case when flag = '3' then conduc else '0' end cel3,
       case when flag = '4' then conduc else '0' end cel4,
       case when flag = '5' then conduc else '0' end cel5,
       case when flag = '6' then conduc else '0' end cel6,
       case when flag = '7' then conduc else '0' end cel7,
       case when flag = '8' then conduc else '0' end cel8,
       case when flag = '9' then conduc else '0' end cel9

from
(
select fecha_hora,
```

```

        avg(convert(float, conduc)) as conduc,
        avg(convert(int, flag)) as flag
    from (
        select fecha, hora, conduc,
            case when elec_11 = '1' and elec_12 = '1' then '1'
                 when elec_12 = '1' and elec_13 = '1' then '2'
                 when elec_13 = '1' and elec_14 = '1' then '3'
                 when elec_14 = '1' and elec_21 = '1' then '4'
                 when elec_21 = '1' and elec_22 = '1' then '5'
                 when elec_22 = '1' and elec_23 = '1' then '6'
                 when elec_23 = '1' and elec_24 = '1' then '7'
                 when elec_24 = '1' and elec_31 = '1' then '8'
                 when elec_31 = '1' and elec_32 = '1' then '9' end flag,
            CONVERT(VARCHAR,fecha)+' '+CONVERT(VARCHAR,hora) as fecha_hora
        from Table_1
        where conduc is not null
    )a group by fecha_hora
    )b
    )c
    order by fecha_hora desc
)e
where flag = '1'

union all

select top 2 *
from (
    select top 45 *
    from (
        select fecha_hora, convert(varchar,flag) as flag,
            case when flag = '1' then conduc else '0' end cel1,
            case when flag = '2' then conduc else '0' end cel2,
            case when flag = '3' then conduc else '0' end cel3,
            case when flag = '4' then conduc else '0' end cel4,
            case when flag = '5' then conduc else '0' end cel5,
            case when flag = '6' then conduc else '0' end cel6,
            case when flag = '7' then conduc else '0' end cel7,
            case when flag = '8' then conduc else '0' end cel8,
            case when flag = '9' then conduc else '0' end cel9
        from (
            select fecha_hora,
                avg(convert(float, conduc)) as conduc,
                avg(convert(int, flag)) as flag
            from (
                select fecha, hora, conduc,
                    case when elec_11 = '1' and elec_12 = '1' then '1'
                         when elec_12 = '1' and elec_13 = '1' then '2'
                         when elec_13 = '1' and elec_14 = '1' then '3'
                         when elec_14 = '1' and elec_21 = '1' then '4'
                         when elec_21 = '1' and elec_22 = '1' then '5'
                         when elec_22 = '1' and elec_23 = '1' then '6'
                         when elec_23 = '1' and elec_24 = '1' then '7'
                         when elec_24 = '1' and elec_31 = '1' then '8'
                         when elec_31 = '1' and elec_32 = '1' then '9' end flag,
                    CONVERT(VARCHAR,fecha)+' '+CONVERT(VARCHAR,hora) as fecha_hora
                from Table_1
                where conduc is not null
            )a group by fecha_hora
        )b
    )c
    order by fecha_hora desc
)e
where flag = '2'

union all

select top 2 *
from (
    select top 45 *
    from (
        select fecha_hora, convert(varchar,flag) as flag,
            case when flag = '1' then conduc else '0' end cel1,
            case when flag = '2' then conduc else '0' end cel2,
            case when flag = '3' then conduc else '0' end cel3,
            case when flag = '4' then conduc else '0' end cel4,
            case when flag = '5' then conduc else '0' end cel5,
            case when flag = '6' then conduc else '0' end cel6,
            case when flag = '7' then conduc else '0' end cel7,
            case when flag = '8' then conduc else '0' end cel8,
            case when flag = '9' then conduc else '0' end cel9
        from (
            select fecha_hora,
                avg(convert(float, conduc)) as conduc,
                avg(convert(int, flag)) as flag
            from (
                select fecha, hora, conduc,
                    case when elec_11 = '1' and elec_12 = '1' then '1'
                         when elec_12 = '1' and elec_13 = '1' then '2'
                         when elec_13 = '1' and elec_14 = '1' then '3'
                         when elec_14 = '1' and elec_21 = '1' then '4'
                    end flag,
                CONVERT(VARCHAR,fecha)+' '+CONVERT(VARCHAR,hora) as fecha_hora
            )a group by fecha_hora
        )b
    )c
    order by fecha_hora desc
)e
where flag = '2'

```

```

        when elec_21 = '1' and elec_22 = '1' then '5'
        when elec_22 = '1' and elec_23 = '1' then '6'
        when elec_23 = '1' and elec_24 = '1' then '7'
        when elec_24 = '1' and elec_31 = '1' then '8'
        when elec_31 = '1' and elec_32 = '1' then '9' end flag,
        CONVERT(VARCHAR,fecha)+' '+CONVERT(VARCHAR,hora) as fecha_hora
    from Table_1
    where conduc is not null
    )a group by fecha_hora
    )b
    )c
    order by fecha_hora desc
    )e
where flag = '3'

union all

select top 2 *
from (
    select top 45 *
    from (
        select fecha_hora, convert(varchar,flag) as flag,
        case when flag = '1' then conduc else '0' end cel1,
        case when flag = '2' then conduc else '0' end cel2,
        case when flag = '3' then conduc else '0' end cel3,
        case when flag = '4' then conduc else '0' end cel4,
        case when flag = '5' then conduc else '0' end cel5,
        case when flag = '6' then conduc else '0' end cel6,
        case when flag = '7' then conduc else '0' end cel7,
        case when flag = '8' then conduc else '0' end cel8,
        case when flag = '9' then conduc else '0' end cel9
    from (
        select fecha_hora,
        avg(convert(float, conduc)) as conduc,
        avg(convert(int, flag)) as flag
    from (
        select fecha, hora, conduc,
        case when elec_11 = '1' and elec_12 = '1' then '1'
        when elec_12 = '1' and elec_13 = '1' then '2'
        when elec_13 = '1' and elec_14 = '1' then '3'
        when elec_14 = '1' and elec_21 = '1' then '4'
        when elec_21 = '1' and elec_22 = '1' then '5'
        when elec_22 = '1' and elec_23 = '1' then '6'
        when elec_23 = '1' and elec_24 = '1' then '7'
        when elec_24 = '1' and elec_31 = '1' then '8'
        when elec_31 = '1' and elec_32 = '1' then '9' end flag,
        CONVERT(VARCHAR,fecha)+' '+CONVERT(VARCHAR,hora) as fecha_hora
    from Table_1
    where conduc is not null
    )a group by fecha_hora
    )b
    )c
    order by fecha_hora desc
    )e
where flag = '4'

union all

select top 2 *
from (
    select top 45 *
    from (
        select fecha_hora, convert(varchar,flag) as flag,
        case when flag = '1' then conduc else '0' end cel1,
        case when flag = '2' then conduc else '0' end cel2,
        case when flag = '3' then conduc else '0' end cel3,

```

```

case when flag = '4' then conduc else '0' end cel4,
case when flag = '5' then conduc else '0' end cel5,
case when flag = '6' then conduc else '0' end cel6,
case when flag = '7' then conduc else '0' end cel7,
case when flag = '8' then conduc else '0' end cel8,
case when flag = '9' then conduc else '0' end cel9
from (
select fecha_hora,
avg(convert(float, conduc)) as conduc,
avg(convert(int, flag)) as flag
from (
select fecha, hora, conduc,
case when elec_11 = '1' and elec_12 = '1' then '1'
when elec_12 = '1' and elec_13 = '1' then '2'
when elec_13 = '1' and elec_14 = '1' then '3'
when elec_14 = '1' and elec_21 = '1' then '4'
when elec_21 = '1' and elec_22 = '1' then '5'
when elec_22 = '1' and elec_23 = '1' then '6'
when elec_23 = '1' and elec_24 = '1' then '7'
when elec_24 = '1' and elec_31 = '1' then '8'
when elec_31 = '1' and elec_32 = '1' then '9' end flag,
CONVERT(VARCHAR, fecha)+' '+CONVERT(VARCHAR, hora) as fecha_hora
from Table_1
where conduc is not null
)a group by fecha_hora
)b
)c
order by fecha_hora desc
)e
where flag = '5'

union all

select top 2 *
from (
select top 45 *
from (
select fecha_hora, convert(varchar, flag) as flag,
case when flag = '1' then conduc else '0' end cel1,
case when flag = '2' then conduc else '0' end cel2,
case when flag = '3' then conduc else '0' end cel3,
case when flag = '4' then conduc else '0' end cel4,
case when flag = '5' then conduc else '0' end cel5,
case when flag = '6' then conduc else '0' end cel6,
case when flag = '7' then conduc else '0' end cel7,
case when flag = '8' then conduc else '0' end cel8,
case when flag = '9' then conduc else '0' end cel9
from (
select fecha_hora,
avg(convert(float, conduc)) as conduc,
avg(convert(int, flag)) as flag
from (
select fecha, hora, conduc,
case when elec_11 = '1' and elec_12 = '1' then '1'
when elec_12 = '1' and elec_13 = '1' then '2'
when elec_13 = '1' and elec_14 = '1' then '3'
when elec_14 = '1' and elec_21 = '1' then '4'
when elec_21 = '1' and elec_22 = '1' then '5'
when elec_22 = '1' and elec_23 = '1' then '6'
when elec_23 = '1' and elec_24 = '1' then '7'
when elec_24 = '1' and elec_31 = '1' then '8'
when elec_31 = '1' and elec_32 = '1' then '9' end flag,
CONVERT(VARCHAR, fecha)+' '+CONVERT(VARCHAR, hora) as fecha_hora
from Table_1
where conduc is not null
)a group by fecha_hora

```

```

        )b
    )c
    order by fecha_hora desc
)e
where flag = '6'

union all

select top 2 *
from (
    select top 45 *
    from (
        select fecha_hora, convert(varchar,flag) as flag,
        case when flag = '1' then conduc else '0' end cel1,
        case when flag = '2' then conduc else '0' end cel2,
        case when flag = '3' then conduc else '0' end cel3,
        case when flag = '4' then conduc else '0' end cel4,
        case when flag = '5' then conduc else '0' end cel5,
        case when flag = '6' then conduc else '0' end cel6,
        case when flag = '7' then conduc else '0' end cel7,
        case when flag = '8' then conduc else '0' end cel8,
        case when flag = '9' then conduc else '0' end cel9
        from (
            select fecha_hora,
            avg(convert(float, conduc)) as conduc,
            avg(convert(int, flag)) as flag
            from (
                select fecha, hora, conduc,
                case when elec_11 = '1' and elec_12 = '1' then '1'
                when elec_12 = '1' and elec_13 = '1' then '2'
                when elec_13 = '1' and elec_14 = '1' then '3'
                when elec_14 = '1' and elec_21 = '1' then '4'
                when elec_21 = '1' and elec_22 = '1' then '5'
                when elec_22 = '1' and elec_23 = '1' then '6'
                when elec_23 = '1' and elec_24 = '1' then '7'
                when elec_24 = '1' and elec_31 = '1' then '8'
                when elec_31 = '1' and elec_32 = '1' then '9' end flag,
                CONVERT(VARCHAR,fecha)+' '+CONVERT(VARCHAR,hora) as fecha_hora
                from Table_1
                where conduc is not null
            )a group by fecha_hora
        )b
    )c
    order by fecha_hora desc
)e
where flag = '7'

union all

select top 2 *
from (
    select top 45 *
    from (
        select fecha_hora, convert(varchar,flag) as flag,
        case when flag = '1' then conduc else '0' end cel1,
        case when flag = '2' then conduc else '0' end cel2,
        case when flag = '3' then conduc else '0' end cel3,
        case when flag = '4' then conduc else '0' end cel4,
        case when flag = '5' then conduc else '0' end cel5,
        case when flag = '6' then conduc else '0' end cel6,
        case when flag = '7' then conduc else '0' end cel7,
        case when flag = '8' then conduc else '0' end cel8,
        case when flag = '9' then conduc else '0' end cel9
        from (
            select fecha_hora,
            avg(convert(float, conduc)) as conduc,

```

```

        avg(convert(int, flag)) as flag
    from (
        select fecha, hora, conduc,
            case when elec_11 = '1' and elec_12 = '1' then '1'
                 when elec_12 = '1' and elec_13 = '1' then '2'
                 when elec_13 = '1' and elec_14 = '1' then '3'
                 when elec_14 = '1' and elec_21 = '1' then '4'
                 when elec_21 = '1' and elec_22 = '1' then '5'
                 when elec_22 = '1' and elec_23 = '1' then '6'
                 when elec_23 = '1' and elec_24 = '1' then '7'
                 when elec_24 = '1' and elec_31 = '1' then '8'
                 when elec_31 = '1' and elec_32 = '1' then '9' end flag,
            CONVERT(VARCHAR, fecha)+' '+CONVERT(VARCHAR, hora) as fecha_hora
        from Table_1
        where conduc is not null
    )a group by fecha_hora
    )b
    )c
    order by fecha_hora desc
    )e
where flag = '8'

union all

select top 2 *
from (
    select top 45 *
    from (
        select fecha_hora, convert(varchar, flag) as flag,
            case when flag = '1' then conduc else '0' end cel1,
            case when flag = '2' then conduc else '0' end cel2,
            case when flag = '3' then conduc else '0' end cel3,
            case when flag = '4' then conduc else '0' end cel4,
            case when flag = '5' then conduc else '0' end cel5,
            case when flag = '6' then conduc else '0' end cel6,
            case when flag = '7' then conduc else '0' end cel7,
            case when flag = '8' then conduc else '0' end cel8,
            case when flag = '9' then conduc else '0' end cel9
        from (
            select fecha_hora,
                avg(convert(float, conduc)) as conduc,
                avg(convert(int, flag)) as flag
            from (
                select fecha, hora, conduc,
                    case when elec_11 = '1' and elec_12 = '1' then '1'
                         when elec_12 = '1' and elec_13 = '1' then '2'
                         when elec_13 = '1' and elec_14 = '1' then '3'
                         when elec_14 = '1' and elec_21 = '1' then '4'
                         when elec_21 = '1' and elec_22 = '1' then '5'
                         when elec_22 = '1' and elec_23 = '1' then '6'
                         when elec_23 = '1' and elec_24 = '1' then '7'
                         when elec_24 = '1' and elec_31 = '1' then '8'
                         when elec_31 = '1' and elec_32 = '1' then '9' end flag,
                    CONVERT(VARCHAR, fecha)+' '+CONVERT(VARCHAR, hora) as fecha_hora
                from Table_1
                where conduc is not null
            )a group by fecha_hora
        )b
        )c
        order by fecha_hora desc
    )e
    where flag = '9'
    ) f group by flag
    ) g
    ) h
'
-- print @sql
exec(@SQL)

```

APÉNDICE D

Datos simulados:

Los datos mostrados corresponden a una simulación, la que entrega el perfil de conductividades del espesador, el nivel de lodos y el porcentaje de sólidos. Esto para los distintos tipos de sedimentación.

Alfa, (tipo de sólido)	Alta Lodos, cm	Conc. Mínima, %v/v	Conc. Máxima, %v/v	Conductividad, mS/cm									Sólido, %v/v	
				Cel_1	Cel_2	Cel_3	Cel_4	Cel_5	Cel_6	Cel_7	Cel_8	Cel_9		
Discreto	7	2.5	2	40	3.629	4.477	4.556	4.828	4.782	4.911	4.871	4.733	4.689	5.500
Discreto	7	3.5	2	40	2.844	4.353	4.591	4.695	4.587	4.862	4.657	4.730	4.782	7.907
Discreto	7	4.5	2	40	2.624	4.482	4.603	4.492	4.588	4.875	4.630	4.799	5.033	7.990
Discreto	7	5.5	2	40	2.484	4.178	4.565	4.757	4.809	4.770	4.738	4.796	4.878	8.315
Discreto	7	6.5	2	40	2.465	4.121	4.650	4.695	4.517	4.733	4.675	4.919	4.725	9.065
Discreto	7	7.5	2	40	2.573	3.462	4.344	4.511	4.545	4.905	4.787	4.775	4.757	10.457
Discreto	7	8.5	2	40	2.476	2.639	4.585	4.751	4.666	4.669	4.586	4.772	4.754	12.008
Discreto	7	9.5	2	40	2.404	2.747	4.189	4.388	4.555	4.572	4.766	4.888	4.954	12.713
Discreto	7	10.5	2	40	2.676	2.770	4.124	4.440	4.698	4.836	4.629	4.976	4.687	11.966
Discreto	7	11.5	2	40	2.465	2.641	4.293	4.391	4.825	4.881	4.850	4.694	4.751	12.207
Discreto	7	12.5	2	40	2.435	2.809	3.691	4.675	4.583	4.893	4.853	4.682	5.000	12.501
Discreto	7	13.5	2	40	2.413	2.786	2.950	4.520	4.654	4.704	4.776	4.878	4.676	14.712
Discreto	7	14.5	2	40	2.685	2.618	2.737	4.497	4.617	4.569	4.828	4.901	4.775	14.951
Discreto	7	15.5	2	40	2.592	2.602	2.889	4.203	4.750	4.762	4.793	4.891	4.702	15.022
Discreto	7	16.5	2	40	2.672	2.740	2.767	4.048	4.617	4.628	4.906	4.973	4.639	15.292
Discreto	7	17.5	2	40	2.722	2.689	2.719	3.383	4.567	4.659	4.862	4.906	4.754	16.591
Discreto	7	18.5	2	40	2.506	2.755	2.764	3.084	4.573	4.632	4.579	4.750	4.818	17.992
Discreto	7	19.5	2	40	2.457	2.467	2.561	3.024	4.334	4.424	4.610	4.611	4.760	20.205
Discreto	7	20.5	2	40	2.501	2.552	2.702	2.937	4.481	4.576	4.746	4.762	4.990	18.543
Discreto	7	21.5	2	40	2.493	2.441	2.430	2.924	4.289	4.752	4.571	4.721	4.915	19.875
Discreto	7	22.5	2	40	2.684	2.639	2.495	2.796	3.454	4.671	4.727	4.587	4.875	20.771
Discreto	7	23.5	2	40	2.529	2.709	2.429	2.735	3.033	4.544	4.803	4.597	4.635	22.453
Discreto	7	24.5	2	40	2.417	2.639	2.554	2.815	2.970	4.406	4.755	4.822	4.961	21.982
Discreto	7	25.5	2	40	2.533	2.471	2.495	2.701	2.874	4.551	4.591	4.763	4.860	22.902
Discreto	7	26.5	2	40	2.363	2.580	2.506	2.601	2.772	4.102	4.742	4.551	4.892	24.204
Discreto	7	27.5	2	40	2.420	2.693	2.542	2.611	2.624	3.692	4.521	4.929	4.946	24.443
Discreto	7	28.5	2	40	2.563	2.473	2.644	2.474	2.799	3.081	4.742	4.712	4.836	25.603
Discreto	7	29.5	2	40	2.570	2.422	2.623	2.677	2.545	2.723	4.626	4.705	4.702	26.955
Discreto	7	30.5	2	40	2.368	2.567	2.659	2.569	2.831	2.686	4.504	4.569	4.646	27.203
Discreto	7	31.5	2	40	2.334	2.408	2.538	2.777	2.713	2.748	4.494	4.622	4.839	27.192
Discreto	7	32.5	2	40	2.339	2.688	2.480	2.445	2.662	2.922	3.550	4.472	4.729	29.166
Discreto	7	33.5	2	40	2.453	2.350	2.559	2.588	2.478	2.812	2.883	4.646	4.994	30.377
Discreto	7	34.5	2	40	2.579	2.596	2.397	2.530	2.628	2.611	2.951	4.528	4.825	30.451
Discreto	7	35.5	2	40	2.669	2.662	2.414	2.612	2.565	2.713	2.822	4.578	4.785	30.074
Discreto	7	36.5	2	40	2.606	2.572	2.542	2.685	2.454	2.827	2.879	4.310	4.820	30.227
Discreto	7	37.5	2	40	2.679	2.368	2.654	2.398	2.824	2.673	2.969	3.604	4.873	31.382
Discreto	7	38.5	2	40	2.447	2.706	2.583	2.640	2.669	2.813	2.897	3.147	4.752	32.000
Discreto	7	39.5	2	40	2.462	2.540	2.688	2.686	2.437	2.675	2.887	2.940	4.793	33.136
Discreto	7	40.5	2	40	2.492	2.478	2.649	2.405	2.461	2.590	2.730	2.862	4.890	34.334
Discreto	7	41.5	2	40	2.546	2.666	2.454	2.516	2.436	2.679	2.722	2.919	4.657	34.123
Discreto	7	42.5	2	40	2.506	2.338	2.706	2.733	2.530	2.732	2.848	2.854	3.688	35.095
Discreto	7	43.5	2	40	2.678	2.474	2.354	2.534	2.706	2.499	2.852	2.625	3.027	37.421
Discreto	7	44.5	2	40	2.533	2.422	2.595	2.663	2.568	2.754	2.790	2.808	2.944	36.718
Discreto	7	45.5	2	40	2.447	2.367	2.653	2.738	2.753	2.472	2.500	2.612	2.920	38.007

Alfa, (tipo de sólido)	Altura Lodos, cm	Conc. Mínima, %v/v	Conc. Máxima, %v/v	Conductividad, mS/cm									Sólido, %v/v	
				Cel_1	Cel_2	Cel_3	Cel_4	Cel_5	Cel_6	Cel_7	Cel_8	Cel_9		
Semi-Discreto	5	2.5	2	40	3.385	4.159	4.350	4.684	4.766	4.876	4.854	4.751	4.727	7.027
Semi-Discreto	5	3.5	2	40	2.723	4.411	4.379	4.547	4.706	4.853	4.816	4.799	5.011	7.763
Semi-Discreto	5	4.5	2	40	2.710	4.087	4.309	4.740	4.656	4.535	4.947	4.825	4.868	8.681
Semi-Discreto	5	5.5	2	40	2.783	3.873	4.187	4.487	4.626	4.613	4.709	4.685	4.740	10.184
Semi-Discreto	5	6.5	2	40	2.736	3.974	4.536	4.606	4.740	4.603	4.823	4.916	4.870	8.471
Semi-Discreto	5	7.5	2	40	2.716	3.516	4.437	4.559	4.552	4.708	4.561	4.655	4.967	10.340
Semi-Discreto	5	8.5	2	40	2.551	2.821	4.079	4.520	4.765	4.674	4.765	4.789	4.992	11.831
Semi-Discreto	5	9.5	2	40	2.651	2.698	4.005	4.283	4.507	4.662	4.547	4.832	4.934	12.824
Semi-Discreto	5	10.5	2	40	2.578	2.759	4.184	4.378	4.461	4.726	4.714	4.675	4.948	12.664
Semi-Discreto	5	11.5	2	40	2.371	2.556	3.975	4.194	4.501	4.705	4.559	4.652	4.849	14.581
Semi-Discreto	5	12.5	2	40	2.620	2.813	3.739	4.282	4.686	4.599	4.656	4.814	5.023	12.993
Semi-Discreto	5	13.5	2	40	2.737	2.789	2.850	4.363	4.411	4.824	4.815	4.915	4.769	14.418
Semi-Discreto	5	14.5	2	40	2.624	2.671	2.953	4.040	4.675	4.537	4.524	4.944	4.952	15.380
Semi-Discreto	5	15.5	2	40	2.727	2.715	2.746	4.047	4.575	4.456	4.754	4.737	4.794	15.962
Semi-Discreto	5	16.5	2	40	2.672	2.618	2.664	4.168	4.481	4.732	4.541	4.951	4.923	15.773
Semi-Discreto	5	17.5	2	40	2.563	2.481	2.826	3.458	4.424	4.752	4.815	4.737	4.732	17.481
Semi-Discreto	5	18.5	2	40	2.509	2.693	2.794	3.080	4.488	4.738	4.749	4.794	4.843	17.660
Semi-Discreto	5	19.5	2	40	2.504	2.593	2.871	3.085	4.123	4.413	4.735	4.661	4.797	19.113
Semi-Discreto	5	20.5	2	40	2.413	2.399	2.709	2.862	4.299	4.627	4.803	4.821	4.876	19.398
Semi-Discreto	5	21.5	2	40	2.611	2.648	2.744	2.871	4.085	4.650	4.825	4.781	4.809	18.803
Semi-Discreto	5	22.5	2	40	2.561	2.552	2.845	2.786	3.471	4.396	4.599	4.634	4.999	20.850
Semi-Discreto	5	23.5	2	40	2.600	2.544	2.769	2.603	3.169	4.511	4.789	4.672	4.632	21.904
Semi-Discreto	5	24.5	2	40	2.380	2.384	2.520	2.789	3.046	4.409	4.396	4.759	4.679	23.661
Semi-Discreto	5	25.5	2	40	2.479	2.518	2.707	2.830	2.910	4.124	4.449	4.629	4.617	23.632
Semi-Discreto	5	26.5	2	40	2.473	2.381	2.758	2.911	2.878	3.987	4.466	4.615	4.733	23.785
Semi-Discreto	5	27.5	2	40	2.388	2.686	2.725	2.859	2.744	3.639	4.467	4.587	4.732	24.415
Semi-Discreto	5	28.5	2	40	2.444	2.432	2.787	2.732	2.772	3.171	4.622	4.785	4.889	24.986
Semi-Discreto	5	29.5	2	40	2.475	2.481	2.574	2.762	2.907	2.874	4.383	4.541	4.878	26.277
Semi-Discreto	5	30.5	2	40	2.476	2.680	2.482	2.721	2.630	2.988	4.431	4.777	4.875	26.037
Semi-Discreto	5	31.5	2	40	2.356	2.659	2.769	2.699	2.606	2.961	4.127	4.458	4.658	27.215
Semi-Discreto	5	32.5	2	40	2.698	2.421	2.694	2.692	2.752	2.954	3.485	4.698	4.726	27.517
Semi-Discreto	5	33.5	2	40	2.475	2.738	2.732	2.642	2.760	2.764	3.045	4.496	4.725	28.860
Semi-Discreto	5	34.5	2	40	2.616	2.510	2.700	2.542	2.761	2.839	2.978	4.406	4.743	29.405
Semi-Discreto	5	35.5	2	40	2.408	2.624	2.627	2.723	2.762	2.819	3.169	4.299	4.605	29.438
Semi-Discreto	5	36.5	2	40	2.480	2.646	2.496	2.718	2.735	2.697	2.886	4.119	4.599	30.690
Semi-Discreto	5	37.5	2	40	2.439	2.689	2.666	2.708	2.561	2.878	2.964	3.632	4.933	30.521
Semi-Discreto	5	38.5	2	40	2.452	2.349	2.474	2.589	2.572	2.735	2.744	3.311	4.696	33.532
Semi-Discreto	5	39.5	2	40	2.631	2.539	2.560	2.488	2.766	2.709	2.945	3.074	4.525	32.742
Semi-Discreto	5	40.5	2	40	2.675	2.398	2.456	2.706	2.807	2.677	2.779	3.016	4.618	33.002
Semi-Discreto	5	41.5	2	40	2.677	2.523	2.616	2.780	2.690	2.857	2.806	2.926	4.685	32.123
Semi-Discreto	5	42.5	2	40	2.531	2.512	2.570	2.521	2.772	2.574	2.737	2.858	3.662	35.482
Semi-Discreto	5	43.5	2	40	2.625	2.404	2.609	2.630	2.553	2.541	2.707	2.700	3.390	36.469
Semi-Discreto	5	44.5	2	40	2.319	2.350	2.556	2.737	2.584	2.648	2.616	2.816	3.158	37.372
Semi-Discreto	5	45.5	2	40	2.509	2.589	2.614	2.455	2.815	2.864	2.772	2.934	2.873	36.000
Semi-Floculento	3	2.5	2	40	3.468	3.854	4.232	4.461	4.701	4.576	4.567	4.903	4.654	8.824
Semi-Floculento	3	3.5	2	40	3.025	4.095	4.351	4.187	4.414	4.587	4.783	4.955	4.854	9.219
Semi-Floculento	3	4.5	2	40	2.950	3.782	4.027	4.222	4.348	4.400	4.653	4.726	4.896	11.270
Semi-Floculento	3	5.5	2	40	2.751	3.650	4.035	4.436	4.344	4.645	4.590	4.695	4.994	11.164
Semi-Floculento	3	6.5	2	40	2.468	3.780	3.882	4.384	4.416	4.484	4.730	4.607	4.661	12.434
Semi-Floculento	3	7.5	2	40	2.781	3.413	3.979	4.335	4.526	4.536	4.854	4.703	4.939	11.332
Semi-Floculento	3	8.5	2	40	2.724	3.145	3.755	4.224	4.239	4.492	4.723	4.622	4.873	13.483
Semi-Floculento	3	9.5	2	40	2.595	3.050	3.973	4.051	4.495	4.651	4.852	4.729	4.684	13.110
Semi-Floculento	3	10.5	2	40	2.702	3.095	3.997	4.302	4.211	4.466	4.749	4.854	4.665	13.791
Semi-Floculento	3	11.5	2	40	2.538	2.952	3.806	4.070	4.182	4.638	4.739	4.611	4.782	14.410
Semi-Floculento	3	12.5	2	40	2.743	2.697	3.888	3.898	4.369	4.680	4.684	4.879	4.803	14.450
Semi-Floculento	3	13.5	2	40	2.384	2.680	3.294	4.071	4.260	4.436	4.573	4.729	4.623	16.735
Semi-Floculento	3	14.5	2	40	2.604	2.708	3.150	3.734	4.131	4.500	4.506	4.760	4.959	16.719
Semi-Floculento	3	15.5	2	40	2.665	2.617	2.903	3.754	4.131	4.578	4.764	4.688	4.775	17.095
Semi-Floculento	3	16.5	2	40	2.513	2.866	2.994	3.615	4.069	4.583	4.605	4.893	4.749	17.038
Semi-Floculento	3	17.5	2	40	2.530	2.974	3.094	3.742	4.172	4.586	4.697	4.760	4.835	16.951
Semi-Floculento	3	18.5	2	40	2.563	2.619	2.876	3.552	4.198	4.526	4.597	4.753	4.776	17.848
Semi-Floculento	3	19.5	2	40	2.485	2.608	2.857	3.375	4.002	4.375	4.730	4.820	4.957	18.386
Semi-Floculento	3	20.5	2	40	2.436	2.737	2.840	3.090	3.685	4.376	4.353	4.822	4.606	20.480
Semi-Floculento	3	21.5	2	40	2.407	2.732	2.864	3.070	3.799	4.068	4.684	4.766	4.833	20.061
Semi-Floculento	3	22.5	2	40	2.676	2.809	2.640	3.026	3.600	4.279	4.664	4.545	4.814	20.286
Semi-Floculento	3	23.5	2	40	2.347	2.543	2.575	3.086	3.386	3.934	4.622	4.755	4.885	22.158
Semi-Floculento	3	24.5	2	40	2.577	2.805	2.621	2.913	3.215	4.228	4.429	4.496	4.884	21.950
Semi-Floculento	3	25.5	2	40	2.516	2.646	2.607	3.060	3.318	3.741	4.438	4.722	4.884	22.366
Semi-Floculento	3	26.5	2	40	2.457	2.467	2.655	2.842	2.967	3.672	4.369	4.450	4.839	24.609
Semi-Floculento	3	27.5	2	40	2.709	2.436	2.829	2.800	3.148	3.422	4.383	4.598	4.811	23.761
Semi-Floculento	3	28.5	2	40	2.660	2.773	2.538	2.974	2.976	3.283	4.283	4.548	4.953	24.032
Semi-Floculento	3	29.5	2	40	2.633	2.698	2.496	2.696	2.930	3.363	4.290	4.425	4.913	25.078
Semi-Floculento	3	30.5	2	40	2.450	2.772	2.769	2.967	3.021	3.243	3.937	4.365	4.909	24.931
Semi-Floculento	3	31.5	2	40	2.415	2.728	2.514	2.763	2.843	3.097	3.850	4.378	4.620	27.251
Semi-Floculento	3	32.5	2	40	2.675	2.646	2.594	2.747	2.930	3.302	3.454	4.277	4.556	27.135
Semi-Floculento	3	33.5	2	40	2.671	2.411	2.795	2.814	2.818	2.937	3.634	4.272	4.689	27.499
Semi-Floculento	3	34.5	2	40	2.617	2.513	2.738	2.774	2.952	3.166	3.253	4.312	4.654	27.566
Semi-Floculento	3	35.5	2	40	2.619	2.483	2.831	2.575	2.672	3.042	3.445	4.155	4.829	28.285
Semi-Floculento	3	36.5	2	40	2.594	2.628	2.773	2.673	3.018	2.830	3.355	4.051	4.732	28.159
Semi-Floculento	3	37.5	2	40	2.639	2.552	2.473	2.859	2.679	2.954	3.140	3.417	4.575	30.680
Semi-Floculento	3	38.5	2	40	2.704	2.641	2.739	2.588	2.989	3.052	3.217	3.522	4.484	29.338
Semi-Floculento	3	39.5	2	40	2.335	2.679	2.626	2.511	2.778	2.896	3.153	3.219	4.497	31.841
Semi-Floculento	3	40.5	2	40	2.554	2.692	2.441	2.594	2.791	2.685	3.225	3.265	4.355	31.966
Semi-Floculento	3	41.5	2	40	2.421	2.621	2.784	2.490	2.830	2.737	2.966	3.326	4.190	32.375
Semi-Floculento	3	42.5	2	40	2.488									





Alfa, (tipo de sólido)	Altura Lodos, cm	Conc. Mínima, %v/v	Conc. Máxima, %v/v	Conductividad, mS/cm									Sólido, %v/v	
				Cel_1	Cel_2	Cel_3	Cel_4	Cel_5	Cel_6	Cel_7	Cel_8	Cel_9		
Alto-Floculento	1	2.5	2	40	3.700	3.647	3.948	4.132	4.063	4.192	4.663	4.841	4.604	11.451
Alto-Floculento	1	3.5	2	40	3.167	3.868	3.789	3.917	4.358	4.556	4.527	4.703	4.913	11.562
Alto-Floculento	1	4.5	2	40	2.887	3.773	3.918	3.969	4.237	4.235	4.483	4.751	4.623	13.116
Alto-Floculento	1	5.5	2	40	2.706	3.734	3.703	4.068	4.103	4.317	4.342	4.719	4.775	13.892
Alto-Floculento	1	6.5	2	40	2.785	3.464	3.926	3.785	4.246	4.298	4.300	4.556	4.912	14.222
Alto-Floculento	1	7.5	2	40	2.794	3.511	3.898	3.805	3.970	4.474	4.404	4.742	4.684	14.200
Alto-Floculento	1	8.5	2	40	2.919	3.552	3.821	3.848	4.070	4.146	4.446	4.579	4.675	14.494
Alto-Floculento	1	9.5	2	40	2.656	3.398	3.720	3.776	4.095	4.138	4.627	4.506	4.666	15.431
Alto-Floculento	1	10.5	2	40	2.874	3.330	3.832	3.671	3.922	4.099	4.341	4.564	4.764	15.674
Alto-Floculento	1	11.5	2	40	2.758	2.932	3.572	3.673	4.071	4.084	4.463	4.794	4.609	16.595
Alto-Floculento	1	12.5	2	40	2.534	3.002	3.736	3.711	3.819	4.333	4.338	4.667	4.876	16.572
Alto-Floculento	1	13.5	2	40	2.830	2.967	3.543	3.883	4.059	4.338	4.325	4.631	4.944	15.629
Alto-Floculento	1	14.5	2	40	2.795	2.926	3.392	3.843	3.768	4.164	4.197	4.666	4.603	17.590
Alto-Floculento	1	15.5	2	40	2.559	2.866	3.370	3.779	3.925	4.005	4.363	4.366	4.699	18.398
Alto-Floculento	1	16.5	2	40	2.697	2.887	3.302	3.627	3.878	4.289	4.429	4.609	4.592	17.750
Alto-Floculento	1	17.5	2	40	2.778	2.810	3.355	3.769	3.916	4.094	4.263	4.458	4.926	17.640
Alto-Floculento	1	18.5	2	40	2.554	2.792	2.971	3.344	3.667	3.849	4.393	4.382	4.865	20.508
Alto-Floculento	1	19.5	2	40	2.582	2.721	3.251	3.521	3.698	4.031	4.428	4.532	4.877	19.044
Alto-Floculento	1	20.5	2	40	2.564	2.740	3.225	3.475	3.848	3.871	4.265	4.624	4.599	19.733
Alto-Floculento	1	21.5	2	40	2.414	2.860	2.951	3.183	3.801	4.031	4.081	4.289	4.588	21.556
Alto-Floculento	1	22.5	2	40	2.414	2.817	2.913	3.404	3.401	3.774	4.380	4.539	4.692	21.409
Alto-Floculento	1	23.5	2	40	2.406	2.685	2.810	3.431	3.602	3.887	4.267	4.536	4.821	21.280
Alto-Floculento	1	24.5	2	40	2.720	2.822	3.037	3.249	3.642	3.918	4.184	4.570	4.678	20.401
Alto-Floculento	1	25.5	2	40	2.490	2.763	3.022	3.082	3.379	3.787	4.014	4.416	4.614	22.691
Alto-Floculento	1	26.5	2	40	2.388	2.573	3.049	3.237	3.475	3.489	3.854	4.565	4.880	22.942
Alto-Floculento	1	27.5	2	40	2.703	2.622	2.708	3.236	3.193	3.695	4.141	4.521	4.504	23.179
Alto-Floculento	1	28.5	2	40	2.538	2.788	2.836	3.172	3.448	3.528	3.849	4.243	4.521	23.780
Alto-Floculento	1	29.5	2	40	2.616	2.530	3.071	2.953	3.115	3.371	3.941	4.318	4.565	24.683
Alto-Floculento	1	30.5	2	40	2.516	2.663	2.903	3.006	3.328	3.437	3.662	4.367	4.799	24.360
Alto-Floculento	1	31.5	2	40	2.747	2.521	2.747	2.871	3.316	3.555	3.702	4.256	4.738	24.769
Alto-Floculento	1	32.5	2	40	2.604	2.535	3.006	2.969	3.241	3.429	3.507	4.207	4.643	25.273
Alto-Floculento	1	33.5	2	40	2.467	2.626	2.795	3.075	3.154	3.275	3.641	4.191	4.802	25.577
Alto-Floculento	1	34.5	2	40	2.691	2.846	2.631	2.820	3.154	3.111	3.344	4.106	4.763	26.563
Alto-Floculento	1	35.5	2	40	2.659	2.698	2.734	3.038	3.292	3.443	3.309	3.696	4.467	26.623
Alto-Floculento	1	36.5	2	40	2.668	2.478	2.806	2.892	3.052	3.422	3.261	3.542	4.696	27.717
Alto-Floculento	1	37.5	2	40	2.417	2.525	2.746	2.940	2.925	3.251	3.395	3.468	4.320	29.226
Alto-Floculento	1	38.5	2	40	2.564	2.525	2.895	3.077	2.916	3.286	3.224	3.657	4.321	28.272
Alto-Floculento	1	39.5	2	40	2.683	2.536	2.885	3.014	2.920	3.114	3.334	3.473	4.297	28.626
Alto-Floculento	1	40.5	2	40	2.691	2.458	2.788	2.735	2.905	2.964	3.334	3.283	3.999	30.709
Alto-Floculento	1	41.5	2	40	2.472	2.576	2.804	2.778	2.922	3.158	3.167	3.491	3.943	30.410
Alto-Floculento	1	42.5	2	40	2.547	2.649	2.605	2.948	2.936	3.208	3.158	3.220	3.502	31.346
Alto-Floculento	1	43.5	2	40	2.451	2.819	2.817	2.872	3.023	2.928	3.356	3.457	3.495	30.486
Alto-Floculento	1	44.5	2	40	2.718	2.699	2.706	2.876	3.046	2.915	3.267	3.464	3.340	30.816
Alto-Floculento	1	45.5	2	40	2.614	2.458	2.903	2.751	2.954	2.949	3.361	3.258	3.597	31.236






APÉNDICE E

Histogramas de error asociados al ajuste comparados con el error del 100% de la muestra



Histogramas para porcentaje de sólidos:







Arquitectura 9x3x2










Arquitectura 9x5x2





















Arquitectura 9x9x2













Arquitectura 9x11x2










Histogramas para altura de lodos:
Arquitectura 9x3x2





















Arquitectura 9x5x2













Arquitectura 9x9x2






Arquitectura 9x11x2







APÉNDICE F

Ejemplo para lectura de datos desde Matlab a SQL Server 2005:

Generar ODBC direccionada a la BD,





Luego en Matlab generar la consulta requerida.

A modo de ejemplo se muestran los siguientes códigos:

Ejemplo 1:

```
clear
logintimeout(5)
conn=database('bdmudline','sa','Password01')
ping(conn)
curs=exec(conn,'select valor, valor2 from perfiles where valor2 > ''3''')
setdbprefs('datareturnformat','numeric')
curs=fetch(curs,1000)
aa=curs.data
close(curs)
close(conn)
```

Ejemplo 2:

```
clear
logintimeout(5)
conn=database('bdmudline','sa','Password01')
ping(conn)
curs=exec(conn,'select top 1 c1, c2, c3, c4, c5, c6, c7, c8, c9 from table_2 order by fecha desc')
setdbprefs('datareturnformat','numeric')
curs=fetch(curs,1000)
aa=curs.data
close(curs)
close(conn)
```


BIBLIOGRAFÍA

A. Uribe-Salas, C.O. Gomez, J.A. Finch. Diciembre 1992, “A conductivity technique for gas and solids holdup determination in three-phase reactors”. *Chemical Engineering Science*, Vol. 49, No. 1, pp. 1-10.

A.R. Leon, L.G. Bergh. 1997, “Uso de redes neuronales en el control de columnas de flotación”. *Información Tecnológica*, Vol. 8, N° 5.

C. Glorieux, J. Moulder, J. Basart, J. Thoen. 1998, “The determination of electrical conductivity profiles using neural network inversion of multi-frequency eddy-current data”. *Appl. Phys.*, Vol. 32, pp. 616–622.

C.O. Gomez, A. Probst, J.A Finch. Noviembre 1998, “Monitoring thickener operation using a conductivity probe”. *Minerals and metallurgical processing*, Vol. 15, No 4.

D.J.C. MacKay. 1992, “Bayesian interpolation,” *Neural Computation*, Vol. 4, No. 3, pp. 415–447.

F. J. Tavera, C. O. Gomez, J. A. Finch. Octubre 1998, “Estimation of gas holdup in froths by electrical conductivity: Application of the standard addition method”. *Minerals Engineering*, Vol. 11, No. 10, pp. 941-947.

F.J. Tavera, R. Escudero, C.O. Gomez, J.A. Finch. Octubre 1997, “Determination of Solids Holdup in Thickeners From Measurement of Electrical Conductivity Using Flow Cells”. *Minerals Engineering*, Vol. 11, No. 3, pp. 233-241.

J. Hilera. 1994, “Fundamentos de redes neuronales. Fundamentos, modelos y aplicaciones”, Addison-Wesley Iberoamericana.

J. Vergouw, C.O. Gomez, J.A. Finch. Octubre 2003, “Estimating true level in a thickener using a conductivity probe”. *Minerals Engineering*, Vol. 17, pp. 87-88.

J.B. Farrow, P.D. Fawell, R.R.M. Johnston. 2000, “Recent developments in techniques and methodologies for improving thickener performance”. *Chemical Engineering Journal* 80 (2000) 149-155.

M. Xu, A. Probst, J.A. Finch. 1994, “Level and solids profile detection in thickener using conductivity”. *CIM Bull.*, 87(985), pp. 46-52.

M.F. Moller. 1993, “A scaled conjugate gradient algorithm for fast supervised learning”, *Neural Networks*, Vol. 6, pp. 525–533.

P. Isasi, I. Galván. 2004, “Redes neuronales artificiales, un enfoque práctico”, Pearson Educación.

R.R.M. Johnston, K. Simic. 1991, "Improving Thickener Operation and Control by Means of a Validated Model". Minerals Engineering, Vol. 4, No. 7-11, pp. 695-705.

S. Banisi, J.A. Finch, A.R. Laplante. Abril 1993, "Electrical conductivity of dispersions: A review". Minerals Engineering, Vol. 6, No. 4, pp. 369-385.

S. Banisi, J.A. Finch, A.R. Laplante. Julio 1994, "Determination of holdup of flake-shaped particles in solid-water systems using conductivity". International Journal of Mineral Processing, Vol. 41, No. 3-4, pp. 311-320.

Y.L. Sidrak. 1996, "Control of counter-current washing operation in alumina production; classical and optimal solutions". Control Eng. Practice, Vol. 4, No. 3, pp. 331-339.

Y.L. Sidrak. Junio 1997, "Control of the Thickener Operation in Alumina Production". Control Eng. Practice, Vol. 5, No. 10, pp. 1417-1426.