

**“MODELIZACIÓN DEL SISTEMA DE MOLIENDA DE
CEMENTO, CON ORIENTACIÓN AL DISEÑO DE UN
OPTIMIZADOR ENERGÉTICO DE LA OPERACIÓN EN
ESTADO ESTABLE. CASO DE ESTUDIO UCEM-PLANTA
GUAPÁN”**

**“MODELIZACIÓN DEL SISTEMA DE MOLIENDA
DE CEMENTO, CON ORIENTACIÓN AL DISEÑO
DE UN OPTIMIZADOR ENERGÉTICO DE LA
OPERACIÓN EN ESTADO ESTABLE. CASO DE
ESTUDIO UCEM-PLANTA GUAPÁN”**

AUTOR:

Ing. Felix Alfredo Mora Espinoza.

Ingeniero Electrónico

Egresado de la Maestría en Automatización y Control Industrial

Jefe de Investigación y Desarrollo UCEM-Planta Guapan

DIRECTOR:

Dr. Ismael Minchala Avila.

Ingeniero Electrónico

Máster en Ciencias con especialidad en Automatización

Doctor en ciencias de ingeniería

Docente de la Maestría en Automatización y Control Industrial



CUENCA – ECUADOR

Datos de catalogación bibliográfica

MORA ESPINOZA FELIX ALFREDO

“MODELACIÓN DEL SISTEMA DE MOLIENDA DE CEMENTO, CON ORIENTACIÓN AL DISEÑO DE UN OPTIMIZADOR ENERGÉTICO DE LA OPERACIÓN EN ESTADO ESTABLE. CASO DE ESTUDIO UCEM-PLANTA GUAPÁN”

Universidad Politécnica Salesiana, Cuenca – Ecuador, 2015
MAESTRIA EN AUTOMATIZACION Y CONTROL INDUSTRIAL

Formato 170 x 240 mm

Páginas: 63

Breve reseña de los autores e información de contacto



FELIX ALFREDO MORA ESPINOZA

Ingeniero Electrónico
Egresado de la Maestría en Automatización y Control Industrial
Jefe de Investigación y Desarrollo UCEM-Planta Guapan
fame5670@gmail.com, fmora@ucem.com.ec



Director:

LUIS ISMAEL MINCHALA AVILA

Ingeniero Electrónico
Máster en Ciencias con especialidad en Automatización
Doctor en ciencias de ingeniería
Docente de la Maestría en Automatización y Control Industrial
minchalai@ieec.org

Todos los derechos reservados.

Queda prohibida, salvo excepción prevista en la Ley, cualquier forma de reproducción, distribución, comunicación pública y transformación de esta obra para fines comerciales, sin contar con autorización de los titulares de propiedad intelectual. La infracción de los derechos mencionados puede ser constitutiva de delito contra la propiedad intelectual. Se permite la libre difusión de este texto con fines académicos investigativos por cualquier medio, con la debida notificación a los autores.

DERECHOS RESERVADOS

©2015 Universidad Politécnica Salesiana.

CUENCA – ECUADOR

MORA ESPINOZA FELIX ALFREDO.

“MODELACIÓN DEL SISTEMA DE MOLIENDA DE CEMENTO, CON ORIENTACIÓN AL DISEÑO DE UN OPTIMIZADOR ENERGÉTICO DE LA OPERACIÓN EN ESTADO ESTABLE. CASO DE ESTUDIO UCEM-PLANTA GUAPÁN”

IMPRESO EN ECUADOR – PRINTED IN ECUADOR

ÍNDICE GENERAL

| | | |
|----------|---|-----------|
| 1 | INTRODUCCIÓN..... | 1 |
| 1.1. | GENERALIDADES..... | 1 |
| 1.2. | OBJETIVOS..... | 3 |
| 1.2.1. | Objetivo general..... | 3 |
| 1.2.2. | Objetivos específicos..... | 3 |
| 1.2.3. | Análisis del estado del arte..... | 3 |
| 1.3. | CONTRIBUCIONES DEL PROYECTO DE INVESTIGACION..... | 4 |
| 2 | MARCO TEÓRICO..... | 5 |
| 2.1. | EL MOLINO DE CEMENTO..... | 5 |
| 2.2. | MODELACIÓN ESTADÍSTICA..... | 8 |
| 2.2.1 | Correlación..... | 10 |
| 2.2.2. | Regresión lineal y no lineal múltiple..... | 11 |
| 2.3. | MODELACIÓN NEURONAL..... | 15 |
| 2.3.1 | Modelos de redes neuronales..... | 16 |
| 2.3.2 | Funciones de activación o transferencia..... | 18 |
| 2.4. | MODELO ANFIS..... | 19 |
| 2.5. | OPTIMIZACIÓN..... | 20 |
| 2.5.1. | Estructura de problemas de optimización..... | 21 |
| 2.5.2. | Algoritmo de optimización..... | 23 |
| 3 | METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR..... | 25 |
| 3.1. | INTRODUCCIÓN..... | 25 |
| 3.2. | VARIABLES DE ESTUDIO..... | 25 |
| 3.3. | PROCESAMIENTO DE LA INFORMACIÓN DE LA BASE DE DATOS..... | 28 |
| 3.4. | ANÁLISIS DE CORRELACIÓN..... | 32 |
| 3.5. | MODELIZACIÓN..... | 35 |
| 3.5.1 | Modelos de regresión múltiple..... | 36 |
| 3.5.2 | Modelización neuronal..... | 40 |
| 3.5.3 | Modelización neurodifusa..... | 42 |
| 3.6. | DISEÑO DEL OPTIMIZADOR..... | 46 |
| 4 | VALIDACIÓN Y PRUEBAS..... | 51 |

| | | |
|----------|---|-----------|
| 4.1. | PRUEBAS DEL COMPORTAMIENTO DE LOS MODELOS | 51 |
| 4.2. | VERIFICACIÓN Y PRUEBAS DEL COMPORTAMIENTO DEL OPTIMIZADOR 56 | |
| 4.3. | ANÁLISIS DE RESULTADOS | 58 |
| 5 | CONCLUSIONES Y RECOMENDACIONES | 59 |
| 5.1. | CONCLUSIONES Y COMENTARIOS | 59 |
| 5.2. | TRABAJO FUTURO | 59 |
| | BIBLIOGRAFÍA | 61 |

ÍNDICE DE FIGURAS

| | |
|---|----|
| Figura 1.1 <i>Proceso de fabricación de cemento</i> | 1 |
| Figura 1.2 <i>Distribución del consumo de energía en el proceso de cemento</i> | 2 |
| Figura 2.1 <i>Molino de cemento</i> | 5 |
| Figura 2.2 <i>Esquema de un separador centrífugo de alta eficiencia</i> | 7 |
| Figura 2.3 <i>Ejemplo de diagrama de dispersión</i> | 10 |
| Figura 2.4 <i>Diseño de la red neuronal</i> | 16 |
| Figura 2.5 <i>Estructura del perceptrón</i> | 17 |
| Figura 2.6 <i>Estructura de la red NARX</i> | 17 |
| Figura 2.7 <i>Función de activación log-sigmoidal</i> | 18 |
| Figura 2.8 <i>Función de activación tan-sigmoidal</i> | 19 |
| Figura 2.9 <i>Función de activación lineal</i> | 19 |
| Figura 2.10 <i>Modelo ANFIS</i> | 20 |
| Figura 3.1 <i>Proceso de molienda de UCEM-Planta Guapán</i> | 26 |
| Figura 3.2 <i>Esquema de flujos con variables</i> | 29 |
| Figura 3.3 <i>Metodología utilizada para el análisis de la información de la base de datos</i> | 29 |
| Figura 3.4 <i>Curvas de variables de análisis</i> | 30 |
| Figura 3.5 <i>Gráficas de capacidad de variables de análisis</i> | 31 |
| Figura 3.6 <i>Gráfica de boxplot con valores atípicos y sin atípicos > a 1,5 de desviación estándar</i> | 33 |
| Figura 3.7 <i>Gráfica de dispersión de las variables entrada y salida</i> | 34 |
| Figura 3.8 <i>Estructura del modelo</i> | 36 |
| Figura 3.9 <i>Metodología utilizada para modelos de regresión</i> | 37 |
| Figura 3.10 <i>Dispersión entre kwh/t y variables de ingreso</i> | 37 |
| Figura 3.11 <i>Tendencia de ingresos vs kwh/t</i> | 38 |
| Figura 3.12 <i>Prueba del modelo de regresión</i> | 39 |

| | | |
|--------------------|--|----|
| Figura 3.13 | <i>CFD y la probabilidad del error del modelo multivariable.....</i> | 40 |
| Figura 3.14 | <i>Metodología de modelación neuronal</i> | 41 |
| Figura 3.15 | <i>Resultado con el modelo ANN</i> | 42 |
| Figura 3.16 | <i>CDF y la probabilidad del error del modelo neuronal.....</i> | 42 |
| Figura 3.17 | <i>Estructura modelo neurodifuso.....</i> | 43 |
| Figura 3.18 | <i>Metodología utilizada para modelos neurodifuso</i> | 43 |
| Figura 3.19 | <i>Arquitectura del modelo neurodifuso.....</i> | 44 |
| Figura 3.20 | <i>Resultado del modelo neurodifuso</i> | 44 |
| Figura 3.21 | <i>CDF y la probabilidad del error del modelo neurodifuso</i> | 45 |
| Figura 3.22 | <i>Resultado de los 3 modelos.....</i> | 45 |
| Figura 3.23 | <i>CDF de los 3 modelos.....</i> | 46 |
| Figura 3.24 | <i>Ejemplo de resultado con optimtool.....</i> | 48 |
| Figura 3.25 | <i>Interfaz del optimizador</i> | 49 |
| Figura 4.1 | <i>Metodología para la validación de los 3 modelos</i> | 52 |
| Figura 4.2 | <i>Respuesta del modelo neuronal con datos posteriores</i> | 52 |
| Figura 4.3 | <i>Respuesta del modelo multivariable con datos posteriores</i> | 52 |
| Figura 4.4 | <i>Respuesta del modelo neurodifuso con datos posteriores</i> | 53 |
| Figura 4.5 | <i>Gráfica de la distribución del error de los 3 modelos.</i> | 54 |
| Figura 4.6 | <i>Gráfica de la probabilidad normal de error de los 3 modelos</i> | 55 |
| Figura 4.7 | <i>Comparación de resultados de los modelos.....</i> | 56 |
| Figura 4.7 | <i>Metodología de la verificación del sistema optimizador.....</i> | 57 |

ÍNDICE DE TABLAS

| | |
|---|----|
| Tabla 3.1 Descripción de las variables | 30 |
| Tabla 3.2 Correspondencia de Variables | 33 |
| Tabla 3.3 Matriz de Correlación de variables entrada y de salida | 33 |
| Tabla 3.4 Rendimiento para una optimización utilizando diferentes algoritmos | 48 |
| Tabla 4.1 Pruebas con datos de modelización | 57 |
| Tabla 4.2 Pruebas con datos posteriores a los de modelización | 58 |

ABREVIATURAS USADAS

| | |
|--------|---|
| ANN | Redes neuronales artificiales |
| ANFIS | Redes neuronales adaptativas basadas en sistemas de inferencia difusa |
| B | Flujo de material, masa por unidad de tiempo |
| Blaine | Superficie específica dada en cm ² /g |
| CL | Carga Circulante |
| CDF | Función de Distribución Acumulada |
| C3S | Silicato Tricálcico (Alita) |
| C2S | Silicato Dicálcico (Belita) |
| kwh | kilovatio hora |
| kwh/t | kilovatio hora por tonelada |
| tph | toneladas por hora |
| rpm | revoluciones por minuto |
| UCEM | Unión Cementera Nacional |

Dedicatoria

A mi esposa, a mis hijos, quienes han anhelado todo el tiempo ver esta meta cumplida.

Ing. Felix Alfredo Mora E.

PREFACIO

El proceso de elaboración del cemento se divide en varias fases. Cada fase tiene un orden específico y un proceso determinado. Estos procesos pueden modificarse para mejorar el rendimiento y calidad de la producción. Una herramienta básica en el mejoramiento de los procesos es un modelo descriptivo que permita relacionar variables de operación con índices de calidad y/o productividad.

Este trabajo de investigación y desarrollo presenta la modelización de una de las fases del proceso para la fabricación de cemento, específicamente, la molienda de cemento. Esta modelización se basa en el estudio de varios tipos de modelos empíricos de entrada - salida. Estos modelos procesan variables de operación y calidad, y entregan como resultado el consumo específico de energía eléctrica de la molienda de cemento.

El planteamiento de un problema de optimización permite la determinación del mejor punto de operación o el punto de operación eficiente. En este caso dicho punto de operación eficiente del proceso de molienda de cemento será aquel que minimice el consumo específico cumpliendo los parámetros establecidos de calidad.

El presente trabajo, cumple con satisfacción la generación de un modelo que permite estimar puntos de operación, optimizando el consumo específico cuando el circuito de molienda de cemento funciona en estado estable.

PRÓLOGO

La investigación realizada durante el desarrollo de este trabajo, ha permitido el desarrollo de un modelo de predicción de consumo de energía por tonelada producida de cemento. Este modelo es usado para optimizar el gasto de energía a través de la operación estable del molino y elegir un punto de funcionamiento eficiente.

El sistema de optimización se ha diseñado en base al conocimiento empírico, teórico y práctico de quienes laboran directamente con el proceso de la molienda de cemento en la UCEM – Planta Guapán.

La metodología de investigación utilizada en este trabajo de tesis es la que se presenta a continuación:

- Identificación de la planta, descripción del proceso y los componentes necesarios
- Obtención y tratamiento de los datos, análisis, limpieza y depuración de observaciones realizadas y almacenadas
- Modelización del consumo energético en el sistema de molienda, simulación numérica
- Validación de los modelos obtenidos, comparación estadística y numérica de los resultados con los datos históricos
- Planteamiento y solución del problema de optimización de operación energética eficiente del molino
- Validación del optimizador, se realizó mediante la prueba con datos históricos

Agradecimientos

A mi familia por el apoyo y la confianza entregados durante mis estudios de maestría, al Dr. Ismael Minchala, director del proyecto de investigación por su disposición y ayuda brindada en el transcurso del planteamiento y desarrollo del proyecto. A Diego, mi cuñado, por toda su ayuda.

Ing. Felix Alfredo Mora E.

CAPÍTULO 1

1 INTRODUCCIÓN

1.1. GENERALIDADES

La producción de cemento requiere de algunas etapas para la transformación de la materia prima en el producto final, que en su orden son: trituración, pre-homogenización, molienda de crudo, homogenización, horno de clinker, molienda de cemento y el empaque (Figura 1.1)

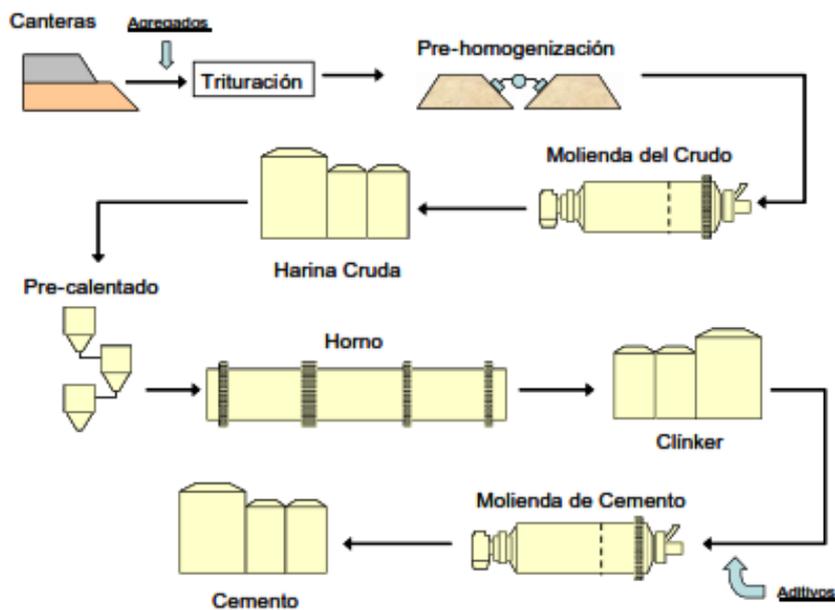


Figura 1.1. Proceso de Fabricación de Cemento (Bahena et al., 2006)

El proceso manufacturero de producción de cemento involucra el uso de equipos con un alto consumo energético. Esta energía proviene de la electricidad o de la energía térmica de combustibles fósiles, como el búnker. La energía eléctrica se utiliza principalmente para la trituración de materias primas y la trituración y molienda de clinker (Madloul, Saidur, Hossain, & Rahim, 2011).

El consumo típico de energía eléctrica de una planta moderna de cemento está entre 110 y 120 kwh por tonelada de cemento (Mejeoumov, 2007). La molienda de cemento

CAPÍTULO 1. INTRODUCCIÓN

constituye la etapa de mayor consumo energético en el proceso de fabricación de cemento (Figura 1.2). Por tanto, el desarrollo de un sistema que optimice la operación del molino en términos de la minimización de su consumo específico, permitirá alcanzar mayores niveles de producción de cemento con un menor costo.

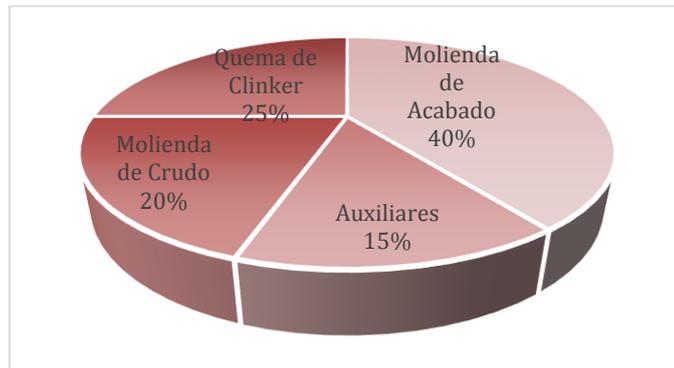


Figura 1.2 Distribución del consumo de energía en el proceso de cemento (Madlool et al., 2011)

La operación del circuito de molienda de UCEM, planta industrial Guapán, se realiza de forma manual y empírica. Un proceso de prueba y error, basado en la experiencia, permite a los operarios ajustar el molino y la dosificación de cada ingrediente. Esto, genera inconvenientes, entre ellos, la pérdida de tiempo, y operación no óptima del proceso.

Este detrimento en la configuración del proceso genera una descompensación entre la producción y el consumo de energía. La planta cuenta con procesos de configuración automatizados empíricos, que han permitido alcanzar puntos de operación energética más eficientes. De ahí la importancia de aplicar la modelización y simulación matemática para optimizar el proceso de molienda de cemento y reducir el consumo de energía (Bahena et al., 2006),(Touil, Belaadi, & Frances, 2006).

Debido a la madurez de las técnicas de modelización y el uso de técnicas de control modernas, como el control de modelo predictivo, proporciona medios para el modelado y control de sistemas industriales complejos de manera eficiente, así se permite una integración total del uso de la información existente en la configuración de sus propios procesos industriales. Es de esta manera que se han introducido nuevos sistemas de modelización y control basados en herramientas de inteligencia artificial, tales como redes neuronales artificiales (RNA) y algoritmos genéticos (GA) (Subbaraj & Anand, 2011).

Esta investigación presenta el desarrollo de un modelo de predicción de consumo específico de energía en el molino de cemento. El modelo procesa variables de

CAPÍTULO 1. INTRODUCCIÓN

operación y de calidad. La estructura del modelo se define utilizando técnicas de inteligencia artificial, y la validación del modelo se realiza a través de pruebas del error de predicción de los modelos; para este propósito se utilizan datos del proceso.

1.2. OBJETIVOS

1.2.1. Objetivo general

Diseñar un sistema de asistencia a la operación en estado estable del proceso del molino de cemento, que permita optimizar el índice de consumo energético por tonelada producida (kwh/t), usando modelos que relacionen variables de calidad, operación y energía.

1.2.2. Objetivos específicos

- Revisar las condiciones de operación del sistema de control instalado para el molino de cemento de UCEM, planta industrial Guapán.
- Diseñar modelos de entrada - salida que relacionen el consumo energético, variables de calidad y variables de operación.
- Establecer un protocolo de pruebas para ajustar el modelo.
- Validar el modelo por medio de simulaciones computacionales en diferentes puntos de operación estable.
- Resolver el problema de optimización del consumo energético del molino, considerando restricciones variables de operación y de calidad impuestas para el tipo de cemento producido.

1.2.3. Análisis del estado del arte

La molienda de cemento es responsable de las características de fineza del producto, medidas típicamente a través de dos variables de calidad: superficie específica (cm^2/g) y porcentaje de retenido en el tamiz 325 ($45\mu\text{m}$) (Mejeoumov,2007). Es necesario por tanto generar estrategias de operación del circuito de molienda de cemento que permitan minimizar la variabilidad del producto final y optimizar el consumo energético del proceso.

En el trabajo de (Sahasrabudhe et al, 2006) se proponen enfoques teóricos basados en modelos para la estimación en línea de variables de calidad y destacan la importancia de la medición en tiempo real de estas variables. En (Jankovic, Valery, & Davis, 2004) se describe la metodología de modelización del circuito de molienda. Estos modelos hacen uso del balance poblacional y el método de Bond aplicando la herramienta de simulación JKSimMet.

En (Tokyay, 1999) se presenta el efecto de la química del clinker sobre el consumo energético del molino de cemento. En (Bahena et al., 2006) se presenta el efecto de

CAPÍTULO 1. INTRODUCCIÓN

estudiar la carga circulatoria en el consumo energético y su correlación con los parámetros del modelo de molienda. En (Sarduym et al., 2013) se presenta un estudio de la receta de alimentación de clinker, yeso y puzolana para optimizar el consumo energético, utilizando modelos de redes neuronales.

En (Minchala, et al. ,2016) se presenta un estudio comparativo de tres diferentes técnicas de modelado para predecir la finura del cemento usando mediciones SCADA de entrada – salida. Los métodos de modelización presentados son ANN, estadísticos, y ANFIS.

Cabe mencionar que las investigaciones mencionadas no tratan con detalle el problema de modelización del consumo específico pero si dan el soporte a esta investigación.

1.3. CONTRIBUCIONES DEL PROYECTO DE INVESTIGACION

Actualmente UCEM planta Guapán, posee un sistema de control en el molino de cemento con el cual se monitorizan las variables de proceso y de energía del sistema. Sin embargo, no existe una herramienta que relacione la operación del circuito de molienda y la calidad en fineza del producto, con el consumo energético por tonelada producida. En este trabajo se desarrollan herramientas que cubren este requerimiento. La siguiente lista enumera las contribuciones de esta tesis en relación al problema de investigación:

- Modelización del consumo específico del molino de cemento utilizando herramientas estadísticas y de inteligencia artificial, redes neuronales y sistemas neurodifusos.
- Implementación de un software para la optimización del consumo específico para el circuito de molienda de la planta de cemento UCEM.
- Modelo de flujo de producción utilizando variables de proceso para estimar el consumo específico.

CAPÍTULO 2

2 MARCO TEÓRICO

2.1. EL MOLINO DE CEMENTO

El análisis del presente trabajo se centra en la etapa de molido del cemento. Esta pulveriza el producto terminado siendo responsable del aspecto y características propias del cemento.

El molino de bolas, utilizado en la molienda del clinker, tiene un diámetro de 3.66 m y una longitud total de 11.28 m, es de tipo horizontal dividido en dos cámaras, la primera de 3.66 m de longitud en la que se realiza la molienda gruesa y la segunda de 7,62 m en la que se realiza la molienda final (Sánchez Christian, Yungaicela Noé, 2015). La Figura 2.1 muestra el esquema del molino de bolas descrito.

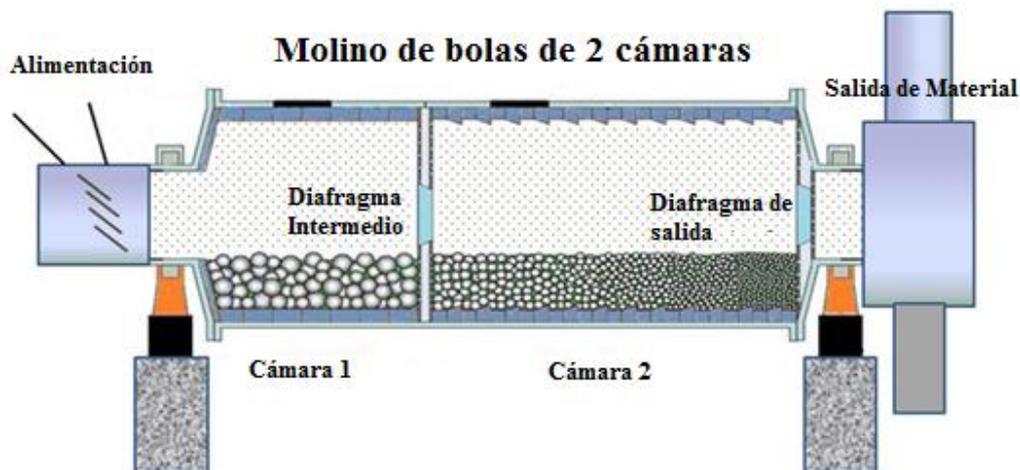


Figura 2.1 Molino de cemento (Marc Piccinin, 2016)

El molino tiene una capacidad de producción medida en función de toneladas por hora de material procesado. La alimentación al circuito de molienda posee una receta pre-establecida. Esta receta especifica las cantidades de cada uno de los ingredientes que compondrán la mezcla de cemento. Dichos ingredientes son: el clinker, yeso y puzolana.

El proceso de molienda de cemento se compone de dos fases determinadas por las cámaras del molino. Durante la primera fase, se realiza un molido grueso al mezclar y

CAPÍTULO 2. MARCO TEÓRICO

triturar los ingredientes iniciales: el clinker y los aditivos (cada componente o ingrediente es dosificado mediante bandas pesadoras a una velocidad controlada). El resultado de esta etapa es un material triturado capaz de pasar a través de un diafragma a la segunda cámara. El espesor de las partículas es determinado por el diafragma y este puede ser personalizado dependiendo las necesidades de producción y calidad.

La primera cámara está compuesta de bolas de acero con diámetros comprendidos entre 30 a 60 milímetros. La segunda cámara, en cambio, contiene bolas de acero con diámetros entre 15 a 25 milímetros. El proceso de molienda se realiza al girar el molino. Este movimiento arrastra las bolas de acero hasta el punto de desequilibrio. En este punto las bolas caerán de tal manera que tanto la fricción como el impacto entre bolas y material generan la trituración de la mezcla. La velocidad de giro del molino está controlada externamente y es responsable del consumo energético.

Al final del proceso y debido a la fineza del material, éste es arrastrado por un flujo de aire. Posteriormente este material será guiado a la siguiente fase, clasificación y almacenaje.

Para operar las diferentes variables del molino existen diferentes equipos de medición. Entre estos están los micrófonos utilizados para monitorear la cantidad de material dentro del molino. Hay que entender que mientras más lleno esté el molino, el sonido producido por el impacto de las bolas será menos estridente. Los valores de decibeles producidos por dichos impactos serán correlacionados con el nivel de llenado del molino. Para el resto de variables del molino, se cuenta con: sensores de corriente, temperatura de los piñones y cojinetes, temperatura de los devanados del motor y temperatura de la salida del material. Los valores medidos en cada sensor, son almacenados en una base de datos. Los operadores también disponen de informes en formato Excel (hojas de cálculo) generados de forma diaria, donde registran cada hora las variables de proceso y de calidad.

Una eficiente operación de la cantidad de material en el interior del molino permitirá trabajar en un punto de eficiencia energética. (Van Breusegem et al., 1996). La variable velocidad de giro del molino es uno de los criterios a considerarse en su operación, de acuerdo a estudios presentados en (Van Breusegem et al., 1996), (Muralidharan, Chidambaram, Recke, & Jorgensen, 2013), la velocidad operativa del molino debe ser el 75% de su velocidad crítica (FLSmidt, 2010). Para el caso de UCEM planta Guapán esta velocidad está en el 75.3% de la velocidad crítica que es de 22.11 rpm.

El material procesado es extraído del molino y conducido al separador a través del elevador de cangilones (identificado como G31). Este posee sensores que monitorean el consumo de corriente.

CAPÍTULO 2. MARCO TEÓRICO

El separador clasifica las partículas de acuerdo a su tamaño. Guapán posee un separador de alta eficiencia marca FLSmidth modelo O-SEPA, cuya estructura es similar a la que se muestra en la Figura 2.2. A continuación se describe el funcionamiento del separador:

- El separador cuenta con un ventilador externo con filtro, que toma el aire entrante a la carcasa a través de dos entradas, a través del conducto de salida en la parte superior del separador junto con el material fino (Sahasrabudhe et al., 2006).
- Las paletas giran en la misma dirección que el rotor. El aire ingresa uniformemente distribuido debido al diseño de las entradas de aire y paletas de guía.
- El rotor amplifica la velocidad del aire, el cual viaja a través de la zona de separación, recogiendo el material fino desde el centro del rotor.
- Por la parte inferior del separador sale el material grueso. Este material se denomina retorno y regresa al molino de cemento para ser reprocesado, cerrando de esta forma el circuito de molienda de cemento.

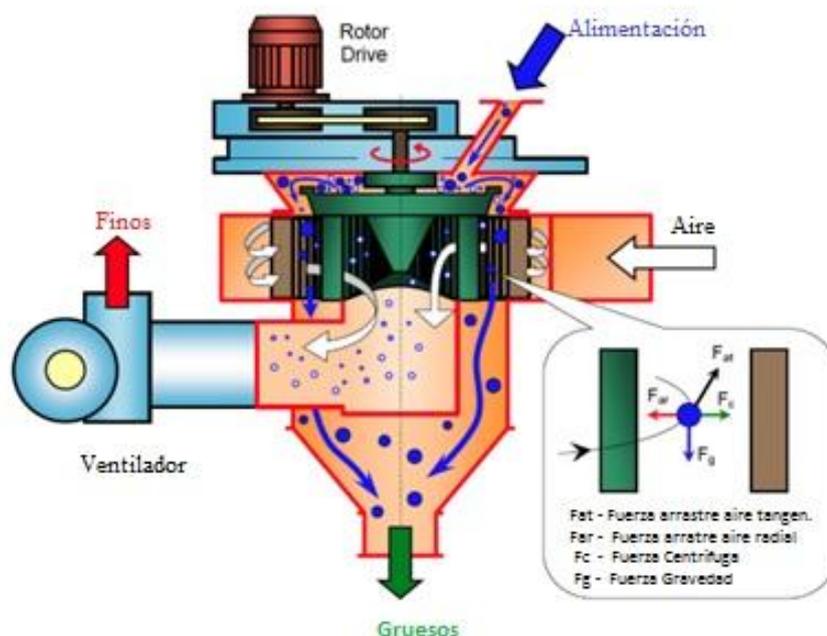


Figura 2.2 Esquema de un separador centrífugo de alta eficiencia (Mejeoumov,2007)

La velocidad del rotor del separador identificado como G35 es controlado desde el panel de control. El parámetro de velocidad de éste rotor determina la propiedad de fineza del producto.

CAPÍTULO 2. MARCO TEÓRICO

El motor de ventilador del colector de polvo del separador, identificado como G39 absorbe las partículas de menor tamaño y las envía hacia los silos de almacenamiento de producto terminado. La consigna de velocidad de éste dispositivo se controla desde el panel de control, permitiendo también variar las características de fineza del producto.

El comportamiento dinámico del molino de cemento, que está influenciado por la calidad del clinker y las condiciones operacionales del proceso, tiene repercusión en la productividad del cemento. La calidad de clinker, medida por el contenido de silicato tricálcico o alita (C3S) y silicato dicálcico o belita (C2S), tiene una alta influencia en la dureza del mismo. Un alto contenido de alita y baja cantidad de belita traduce en una mejor molturabilidad, o mejor facilidad de molienda.

La variable CaO viene relacionado con el porcentaje de puzolana, con el uso de puzolana se reemplaza el clinker hasta en un 40% según norma INEN 490. El costo de la puzolana es 4 veces menos que el de clinker. Al considerar esta variable es posible obtener un modelo de producción que dependa de la calidad del clinker y sugiera un valor óptimo de puzolana en la alimentación al molino de cemento.

2.2. MODELACIÓN ESTADÍSTICA

Para entender el comportamiento de un conjunto de datos o de un proceso, es necesario realizar varias observaciones, capturar datos y realizar cálculos sobre los mismos. Este proceso se puede realizar mediante cálculos estadísticos inferenciales y se le denomina modelamiento estadístico. Dicho modelamiento permite describir e interpretar el conjunto completo de datos por medio de análisis de subconjuntos de dichos datos. Para entender el modelamiento se brinda a continuación un breve resumen de los conceptos básicos de estadística. Se iniciará por conceptualizar lo que es estadística y sus componentes principales. Luego se describirán los diferentes conceptos propios de la estadística y los cálculos utilizados en el proceso de investigación aplicado en el modelamiento del molino de cemento.

El concepto de estadística nos indica que todo conjunto de datos puede ser descrito por medio de ciertos valores calculados a partir de una muestra de los mismos. Es decir, la estadística organiza, presenta, analiza, e interpreta datos con el fin de facilitar la toma de decisiones de forma eficaz. La estadística está dividida en dos tipos, la descriptiva que consiste en organizar y resumir los datos; y, la inferencial, la cual permite entender como se comporta un conjunto completo de datos (población), basada en cálculos sobre una parte pequeña, denominada muestra, de esa población. (Lind, Douglas A.; Marchal, William G; Wathen, 2008), (Geoffrey Vining & Kowalski, 2011). Para el análisis estadístico, los datos se denominan variables y se dividen en dos tipos:

CAPÍTULO 2. MARCO TEÓRICO

1. Variables cuantitativas que son aquellas que se presentan de forma numérica. Las variables cuantitativas, a su vez se subdividen en dos tipos:
 - a) Discretas, aquellas que toman ciertos valores y existen vacíos entre estos.
 - b) Continuas, aquellas que adoptan cualquier valor en un intervalo específico. Ejemplo sería la velocidad de giro de un rotor.
2. Variables cualitativas son aquellos datos que no son numéricos.

Los estudios sobre las variables cuantitativas nos permiten determinar valores tales como la media, el promedio, la mediana, la correlación, las tasas de incremento, la varianza, el rango, la media geométrica, y, la desviación estándar. Así también, una vez entendidos los datos, es posible aplicar la estadística inferencial para generar modelos de comportamiento o de patrones. Esos modelos de comportamiento permiten determinar pruebas de hipótesis, estimaciones de valores, pronósticos de futuras observaciones, descripciones de asociaciones o correlación, o, modelamiento de relaciones entre variables. Este último, el modelamiento de relaciones entre variables, también llamado análisis de regresión, es el proceso necesario para el tema de estudio del molino de cemento. El análisis de regresión será descrito de una manera más profunda, (Lind, Douglas A.;Marchal, William G ;Wathen, 2008) .

Una muestra representativa de la población, describe correcta y totalmente a una población completa. Se deben utilizar muestras de datos con criterio estadístico para disminuir los problemas que conllevan estudiar a toda la población. La muestra, al representar a la población total, tiene características y propiedades similares. Es más, todo resultado de cualquier cálculo realizado sobre la muestra será igual que haberlo realizado sobre la población total. Esto nos da una ventaja en cuanto a tiempo, costo y facilidad de manejo de los datos.

Una muestra puede generarse de forma aleatoria, de forma sistemática, de forma estratificada o por conglomerados. Para el caso del molino de cemento se ha realizado un muestreo sistemático. Este proceso selecciona un punto de partida aleatorio y luego selecciona cada k-ésimo elemento subsiguiente de la población para formar la muestra.

Los estudios realizados sobre la muestra permiten determinar estimadores e intervalos de confianza. Un estimador es un valor estadístico que sirve para estimar ese mismo parámetro para la población total. Un intervalo de confianza es un conjunto de valores entre los cuales se espera que ocurra el parámetro de la población. El tamaño de un intervalo de confianza viene determinado por el número de observaciones, la variabilidad en la población, (desviación estándar), y el nivel de confianza. Dentro de una muestra se puede determinar una proporción. Esta proporción, es una razón, fracción o porcentaje que indica que cierta parte de la muestra o población posee una característica particular. Una proporción se puede calcular al definir el número de

CAPÍTULO 2. MARCO TEÓRICO

eventos que tienen dicha característica particular y dividir dicha cantidad entre el número total de observaciones.

Por otro lado, calcular el tamaño de una muestra, generalmente es el reto más grande dentro de la estadística. Es posible determinar un tamaño apropiado de muestra. Para ellos se brinda a continuación tres factores:

1. El margen de error máximo
2. El nivel de confianza deseado
3. La variación de la población

Existen procesos para verificar los resultados de los cálculos realizados y estos son las pruebas de hipótesis y el análisis de la varianza.

2.2.1 Correlación

La regresión lineal permite describir la relación entre variables en un problema que busca entender el patrón de comportamiento de un conjunto de datos. Una vez descrito dicho patrón es posible generar un modelo que permita el pronóstico de valores futuros dependientes de la relación existente entre las variables que describen el problema.

Típicamente, el primer análisis previo al desarrollo de un modelo de regresión, es la presentación gráfica de las muestra en un diagrama de dispersión. Este diagrama representa la relación existente entre dos variables. Estas dos variables tienen una característica particular y es que una de dichas variables depende de la otra. Es por esa razón que son llamadas variable dependiente e independiente. La consigna es la de presentar a los valores de la variable independiente en el eje de las X (horizontal) y los valores que corresponden a la variable dependiente en el eje de las Y (vertical). A la variable independiente se la conoce como estimador, Figura 2.3.

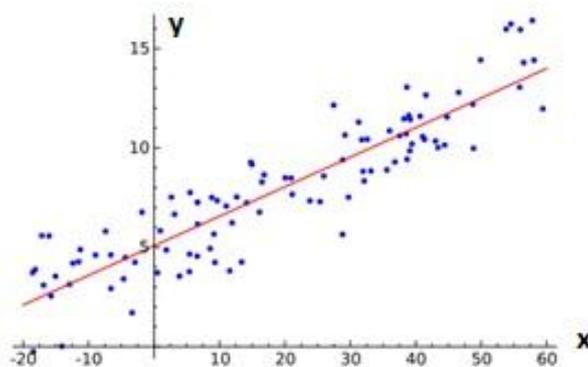


Figura 2.3 Ejemplo de diagrama de dispersión

CAPÍTULO 2. MARCO TEÓRICO

Un diagrama de dispersión permite definir la fortaleza existente en la relación entre las dos variables. Al valor calculado se le da el nombre de correlación e indica la fuerza y la dirección de una relación entre dos variables. Dicho de una manera más descriptiva, la existencia de correlación entre dos variables determina que si la variable independiente aumenta los valores también lo debe hacer la variable dependiente. El coeficiente de correlación mide la fuerza de la asociación lineal entre dos variables. El valor de este coeficiente está entre -1 y 1. Si el valor de dicho coeficiente es cero (0), ninguna asociación existe entre las variables. Se considera una correlación positiva perfecta cuando el valor es de 1 y se considera una correlación negativa perfecta cuando el valor es de -1.

El signo, positivo o negativo, del coeficiente de correlación indica una relación directa o inversa, respectivamente entre las variables. En estadística se le designa la letra r y se determina mediante la ecuación (2.1):

$$r = \frac{\sum(x-\bar{x})(y-\bar{y})}{(n-1)s_x s_y} \quad (2.1)$$

donde x es el valor de la variable independiente, \bar{x} es la media de los valores independientes, y es la variable dependiente del valor x , \bar{y} es la media de los valores dependientes, y $S_x S_y$ son las desviaciones estándar para cada grupo de valores.

2.2.2. Regresión lineal y no lineal múltiple

En el análisis de regresión, se estima una variable que depende de otra variable. Aquella variable a ser estimada es la variable dependiente. Por tanto, la variable utilizada para realizar la estimación es la variable independiente. La relación existente entre dichas variables debe ser lineal. La ecuación de regresión se determina por medio del criterio de mínimos cuadrados. El principio de los mínimos cuadrados determina una ecuación de regresión al minimizar la suma de los cuadrados de las distancias verticales entre los valores reales de la variable dependiente y los que se estimaron.

La recta de regresión de mínimos cuadrados es de la forma :

$$\hat{y} = a + bx \quad (2.2)$$

donde: \hat{y} es el valor estimado de y para un valor seleccionado de x , a se calcula con la siguiente ecuación $a = \bar{y} - b\bar{x}$, b es la pendiente de la recta ajustada. Muestra la cantidad de cambio de \hat{y} ante un cambio de una unidad de x . El signo de b y el del coeficiente r , siempre son iguales. El valor de b se calcula mediante $b = r \left(\frac{S_y}{S_x} \right)$, x es el valor de la variable independiente.

CAPÍTULO 2. MARCO TEÓRICO

Un modelo que estime de manera eficiente el patrón de comportamiento de un problema con múltiples entradas requiere un análisis de regresión múltiple, que se presenta en la siguiente sección.

Regresión no lineal

La forma general de la regresión no lineal está dada por:

$$Y_i = f(X_i, \gamma) + \varepsilon_i \quad (2.3)$$

donde:

$$X_i = \begin{bmatrix} X_{i1} \\ X_{i2} \\ \vdots \\ X_{iq} \end{bmatrix} \quad \gamma = \begin{bmatrix} \gamma_0 \\ \gamma_1 \\ \vdots \\ \gamma_{p-1} \end{bmatrix} \quad (2.4)$$

Cada observación Y_i se postula a ser la suma de la respuesta media $f(x)$ en función de la respuesta no lineal dada y un término de error aleatorio ε . Una diferencia importante del modelo de regresión no lineal es que el número de parámetros de regresión no es necesariamente relacionado con el número de variables X en el modelo. En modelo de regresión lineal el número $p-1$ de X variables implican entonces p coeficientes de regresión.

Para la estimación con mínimos cuadrados se trata de minimizar el criterio en el Q es:

$$Q = \sum_{i=1}^n [Y_i - (\beta_0 + \beta_1 X_i)]^2 \quad (2.5)$$

Aquellos valores de β_0 y β_1 que minimice Q para las muestras (X_i, Y_i) son las estimaciones de mínimos cuadrados y se denotan por b_0 y b_1 . Como mínimo, se pretende obtener estos valores de los parámetros asociados con la mejor curva de ajuste. Con el fin de determinar si el modelo es adecuado, puede ser necesario utilizar conceptos de inferencia estadística tales como intervalos de confianza para los parámetros así como pruebas de bondad de ajuste (Seber & Wild, 1989)(Bethea, Duran, & Boullion, 1985)(Kutner, Nachtsheim, Neter, & Li, 2004).

Modelo de regresión lineal múltiple

El modelo de regresión lineal múltiple es representado por la ecuación:

CAPÍTULO 2. MARCO TEÓRICO

$$\hat{y} = a + b_1x_1 + b_2x_2 + \dots + b_kx_k \quad (2.6)$$

donde: a es la intersección con el eje Y cuando las variables independientes x son iguales a 0, b_j es cada uno de los coeficientes de regresión de la muestra, x_j representa cada valor que toma la variable independiente

El número de variables independientes es indefinido. Si en un momento dado existiera un exceso de variables independientes o si existiera una correlación (multicolinealidad, colinealidad) entre ellas, se debería realizar un estudio de componentes principales para definir aquellas variables independientes que pueden ser obviadas del estudio (Lind, Douglas A.; Marchal, William G ; Wathen, 2008).

Para el análisis de la regresión múltiple se crea una tabla de análisis de varianzas (ANOVA) la cual permite comparar varias medias poblacionales en forma simultánea. Este estudio debe cumplir los siguientes supuestos:

- las poblaciones siguen la distribución normal
- las poblaciones tienen desviaciones estándar iguales
- las poblaciones son independientes

La ecuación de regresión tiene dos medidas de su eficacia, el error estándar de estimación múltiple y el coeficiente de determinación múltiple.

1. Error estándar de estimación múltiple; es similar a la desviación estándar. Se mide en las mismas unidades que la variable dependiente. Se basa en desviaciones cuadráticas de la ecuación de regresión. Varía de cero (0) a más infinito. La ecuación (2.7) muestra su cálculo.

$$S_{y.123\dots k} = \sqrt{\frac{\sum(y-\hat{y})^2}{n-(k+1)}} \quad (2.7)$$

2. Coeficiente de determinación múltiple; reporta el porcentaje de la variación de la variable dependiente que explica el conjunto de variables independientes. Puede variar de 0 a 1. También se basa en desviaciones cuadráticas de la ecuación de regresión. Y se determina mediante la ecuación (2.8)

$$R^2 = \frac{\sum(\hat{y}-\bar{y})^2}{\sum(y-\bar{y})^2} \quad (2.8)$$

Para el coeficiente *de determinación múltiple*, cuándo el número de variables independientes es grande, se ajustan los grados de libertad utilizando (2.9)

$$R_{ajust}^2 = 1 - \frac{\frac{\sum(y-\hat{y})^2}{n-(k+1)}}{\frac{\sum(y-\bar{y})^2}{n-1}} \quad (2.9)$$

CAPÍTULO 2. MARCO TEÓRICO

Una vez que se ha modelado el problema y se tienen estimaciones calculadas se pueden realizar pruebas para investigar si alguna de las variables independientes tiene coeficientes de regresión significativos. Para esto, se establece la hipótesis de que todos los coeficientes son cero y otra alternativa que indique que al menos un coeficiente de regresión es diferente de cero. Para lograr esto se utiliza como el *estadístico* de prueba a la distribución F (Ronald Fisher)(Lind, Douglas A.; Marchal, William G ;Wathen, 2008). La fórmula para calcular el estadístico de prueba (F) de la prueba global es (2.10)

$$F = \frac{\frac{\sum(\hat{y}-\bar{y})^2}{k}}{\frac{\sum(y-\hat{y})^2}{[n-(k+1)]}} \quad (2.10)$$

donde k es el número de variables independientes y n es el tamaño de la muestra.

La siguiente prueba determina cuales variables tienen coeficientes de regresión distintos de cero. Aquellas variables que tengan coeficientes iguales a cero son omitidas del análisis. El estadístico de prueba es la distribución t , su fórmula es:

$$t = \frac{b_i - 0}{s_{b_i}} \quad (2.11)$$

Para poder emplear el análisis de regresión, es necesario considerar cinco suposiciones

- La relación entre las variables independientes y la dependiente debe ser lineal.
- La variación es la misma tanto para los valores grandes como pequeños de \hat{y} , a esta suposición se la define como homoscedasticidad.
- Los residuos siguen la distribución de probabilidad normal.
- Las variables independientes no están correlacionadas. Para esto se genera una matriz de correlaciones donde se muestran todas las correlaciones entre las variables independientes. El intervalo aceptado de correlación entre variables independientes es $[-0.70; 0.70]$. Entre las señales de variables independientes correlacionadas se encuentran los casos cuando una variable de predicción se considera insignificante, cuando se presenta una inversión de signos en una o más de las variables independientes, o bien cuando, al eliminar una variable de la solución, se produce un gran cambio en los coeficientes de correlación. El factor de inflación de la varianza (VIF) se emplea para identificar variables independientes correlacionadas, y su ecuación es:

$$VIF = \frac{1}{1-R_j^2} \quad (2.12)$$

- Cada residuo es independiente de otros residuos.

CAPÍTULO 2. MARCO TEÓRICO

2.3. MODELACIÓN NEURONAL

La modelización de un proceso comprende la abstracción de éste, ignorando en ciertos casos no linealidades y relaciones intervariables complicadas. Para ello se divide el proceso en cada uno de sus componentes, variables, características y demás. La sección anterior describe la metodología de modelización estadística. Sin embargo, existen otras maneras de obtener una simulación del comportamiento de un proceso. Para entender mejor esto, es factible comparar con el proceso de aprendizaje que tiene el ser humano. Dicho proceso de aprendizaje se basa en la prueba y error, hasta que la práctica genera una perfección en la realización de un proceso. La mejor manera de lograr esto es mediante la simulación de como el cerebro aprende. Es aquí donde el concepto de red neuronal puede ser descrito.

Una red neuronal es una simulación de las neuronas cerebrales y como éstas interactúan entre sí. A estas simulaciones del funcionamiento del cerebro se les ha dado el nombre de redes de neuronas artificiales (ANN, por sus siglas en inglés). Se las puede describir como un conjunto de capas. Cada capa tiene una función diferente y complementaria a las otras. Cada capa, a su vez, tendrá entradas y salidas. Cada entrada puede ser la salida de una capa o neurona previa. Una capa está compuesta de una o varias neuronas. Cada neurona realizará tareas específicas con las entradas ingresadas y, de ser necesario, otros datos correspondientes. En resumen, las ANN procesan información mediante la interconexión de unidades básicas llamadas neuronas. La neurona recibe señales de sensores externos o de otras neuronas a través de sus conexiones de entrada.

Cada conexión entre capas o neuronas tiene asociados dos parámetros:

1. Un peso W que se encarga de asignar un factor de ponderación para dar una mayor o menor importancia a la señal que transmite (I. Viñuela, P.Galván, 2004.).
2. Un umbral b , el cual no depende de ninguna entrada y se trata de un parámetro interno de la red.

La Figura 2.4 muestra el diseño de una red neuronal artificial, y se describe matemáticamente por la ecuación (2.13):

$$\vec{S} = F(F(\vec{X} W1 + b1) W2 + b2) \quad (2.13)$$

donde $W1$ y $W2$ son la matriz de pesos correspondientes a cada neurona, $b1$ y $b2$ son los umbrales correspondientes a cada neurona, S es el conjunto de estados posibles de la red neuronal, X corresponde a las entradas aplicadas en la red, y F es una función de activación.

CAPÍTULO 2. MARCO TEÓRICO

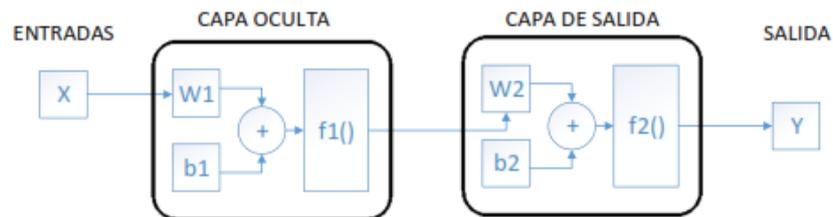


Figura 2.4 Diseño de la red neuronal

Primero se realiza una suma ponderada conjuntamente con los umbrales, luego se aplica una función de transferencia que puede ser lineal o no lineal. Si la función es lineal se reduce a una regresión lineal de datos. Si la función es no lineal permite la capacidad de generalización en diversos aspectos, como por ejemplo redes neuronales utilizadas para ajustar funciones, para clasificar conjuntos de datos o para reconocer patrones (I. Viñuela, P.Galván, 2004). Para este caso la red neuronal permite la modelización de la variable de consumo específico.

2.3.1 Modelos de redes neuronales

Las redes neuronales pueden ser clasificadas en función del sentido del flujo de la información y del número de capas que intervengan en el proceso.

En base a esto se tienen las redes de propagación hacia adelante (*feedforward*), el flujo de información va desde la capa de entrada hasta la de salida sin que existan ciclos o conexión que lleven la información hacia atrás, como se muestra en la Figura 2.5. El perceptrón multicapa es una estructura unidireccional donde la información va desde las neuronas de entrada a las de salida sin ningún tipo de lazo de control o realimentación (I. Viñuela, P.Galván, M. Inés, 2004). Con este tipo de redes neuronales es posible aproximar cualquier función continua que contenga al menos una capa oculta de neuronas (Zhang, et al.,2005).

CAPÍTULO 2. MARCO TEÓRICO

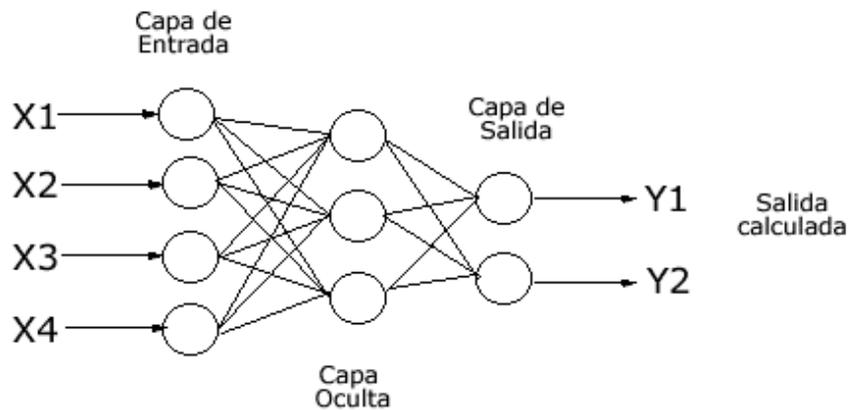


Figura 2.5 Estructura del perceptrón

Otro modelo de ANN es una red NARX (*nonlinear autoregressive exogenous model*), que es similar a la anterior pero presenta una realimentación desde su salida hasta las neuronas de entrada, como se observa en la Figura 2.6. Conteniendo módulos TDL (*tapped delay line* por sus siglas en inglés) que son líneas con retardo de tiempo. La NARX es una red recurrente que además de realimentar la salida de la red, realimenta el error cometido por la misma en predicciones pasadas.

Las características del problema en estudio permiten la aplicación de varios de los modelos descritos. Esta versatilidad permite un estudio más profundo del efecto de cada uno sobre la información. Por lo tanto, el método utilizado dependerá de las condiciones del problema para el uso una red u otra en un momento determinado

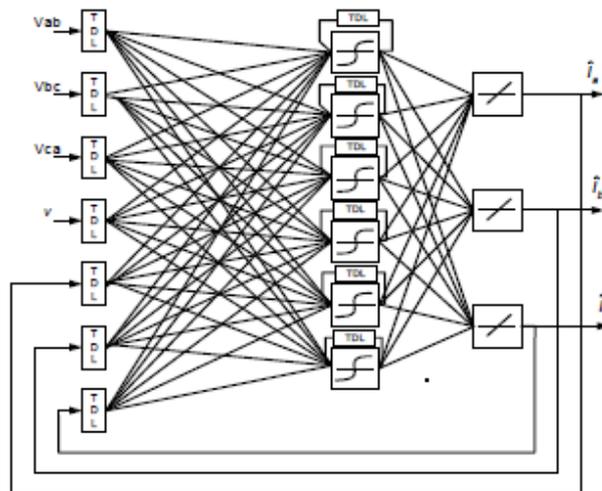


Figura 2.6 Estructura de la red NARX

CAPÍTULO 2. MARCO TEÓRICO

La estructura de una ANN es *feedforward*, consta básicamente de tres tipos de capas de neuronas como se observa en la Figura 2.5.

Capa de entrada: es donde se incorporan los valores de las entradas y se introducen en la red para pasar la información a las siguientes capas. Esta capa proporciona la información de las variables de entrada.

- Capa de salida: se recoge la información proveniente de las neuronas de la capa de entrada y se envía a las salidas correspondientes de la red. Esta capa tiene el mismo número de neuronas correspondientes al número de salidas.
- Capas ocultas: es la capa o múltiples capas que hay entre la capa de entrada y la capa de salida. Son las encargadas de establecer las relaciones entre las variables de entrada. Dependerá de las funciones de activación. La cantidad de capas ocultas aumenta el tiempo de procesamiento.

2.3.2 Funciones de activación o transferencia

Las neuronas dentro de una red neuronal se activan mediante el uso de una función de transferencia, lo cual caracteriza su respuesta a la salida de la neurona. Las principales funciones de activación son lineales, sigmoideas, logarítmicas, tangenciales, etc. MATLAB incorpora tres funciones de activación que se describen a continuación.

- Log-sigmoidal (logsig): es la función de transferencia logarítmica. La función recibe como entrada valores desde $-\infty$ a $+\infty$ y genera salidas entre 0 y 1. La Figura 2.7 muestra la función log-sigmoidal.

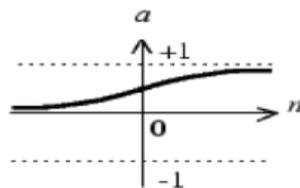


Figura 2.7 Función de activación log-sigmoidal

- Tan-sigmoidal (tansig): es la función de transferencia tangencial. La función recibe como entrada valores desde $-\infty$ a $+\infty$ y genera salidas entre -1 y 1. La Figura 2.8 muestra la función log-sigmoidal.

CAPÍTULO 2. MARCO TEÓRICO

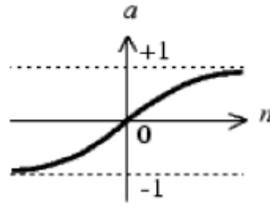


Figura 2.8 Función de activación tan-sigmoidal

- Purelin: es la función de transferencia lineal. La salida de la función es igual a su entrada. La función de activación purelin se observa en la Figura 2.9.

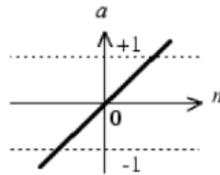


Figura 2.9 Función de activación lineal

2.4. MODELO ANFIS

Uniando dos metodologías, la neural que proporciona la capacidad de aprender, y la difusa que proporciona capacidad de representar el conocimiento, en tecnologías inteligentes en general, puede conducir a una mejor tecnología que aprovecha los puntos fuertes de cada una y al mismo tiempo supera algunas limitaciones técnicas individuales de estas. Esta unión se da en modelización ANFIS (*adaptive network fuzzy inference systems* por sus siglas en inglés).

Los conceptos difusos que se incorporan en las redes neuronales en cualquier nivel son: La regla difusa Mamdani que es de la forma:

“Si x is A entonces y es B ”

la regla difusa Sugeno que es de la forma:

“Si x is A entonces y is $f(x)$ ”

CAPÍTULO 2. MARCO TEÓRICO

donde A y B son conjuntos difuso o productos de conjuntos difusos, y f es una función de valor - real.

La Figura 2.10 muestra el modelo general del ANFIS dividido por capas. La primera capa contiene las funciones de membresía, la salida de cada nodo especifica el grado de pertenencia para cada una de las entradas. La segunda capa calcula el grado de activación de la regla asociada. El operador lógico difuso utilizado es AND. (Jyh-Shing Roger Jang, 1993):

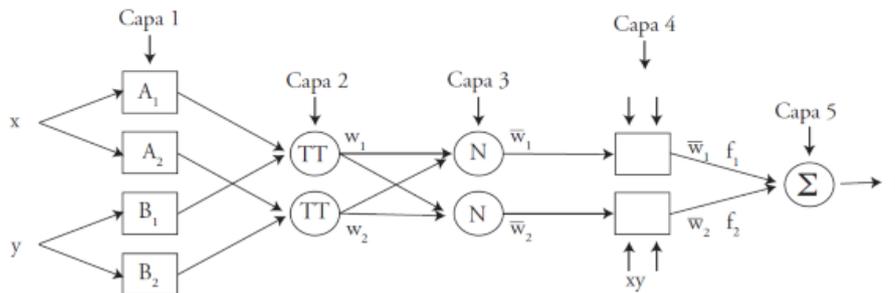


Fig.2.10 Modelo ANFIS (Nguyen, Prasad, Walker, & Walker, 2003)

La tercera capa normaliza los grados de activación encontrados en la segunda capa. La cuarta capa realiza el producto del grado de activación normalizado y la salida de cada regla. Finalmente, la quinta capa muestra la salida total del sistema como la suma de todas las entradas a este nodo. El proceso se resume mediante estos 5 niveles (Jyh-Shing Roger Jang, 1993):

1. Proceso de fuzificación de las entradas.
2. Computo de reglas que salen del primer nivel
3. Normalización de las reglas
4. Determinación de parámetros de las reglas subsecuentes; se usa backpropagation para determinar parámetros de las premisas
5. Ajuste de los parámetros.

(Sánchez Ayora, Christian Eduardo; Yungaicela Naula, 2015)

2.5. OPTIMIZACIÓN

La optimización es el proceso de maximizar o minimizar una función objetivo deseado al tiempo que satisface las restricciones imperantes (Belegundu & Chandrupatla, 1999). La optimización es el acto de lograr el mejor resultado posible en determinadas circunstancias (Astolfi, 2010).

Un problema de optimización convexo, tiene la forma:

CAPÍTULO 2. MARCO TEÓRICO

$$\begin{aligned} & \text{minimizar } f_0(x) \\ & \text{sujeto a } f_i(x) \leq b_i, \quad i = 1, \dots, m \end{aligned} \quad (2.14)$$

donde: x representa la variable de optimización del problema, la función $f_0: \mathbf{R}^n \rightarrow \mathbf{R}$ es la función objetivo, las funciones $f_i: \mathbf{R}^n \rightarrow \mathbf{R}$, $i = 1, \dots, m$, son inecuaciones o funciones de restricción, y las constantes b_1, \dots, b_m son los límites o fronteras, de las restricciones.

Un vector x^* es llamado óptimo, o una solución del problema (2.14), si tiene el valor objetivo más pequeño entre todos los vectores que satisfacen las restricciones: para cualquier z con $f_1(z) \leq b_1, \dots, f_m(z) \leq b_m$, teniendo $f_0(z) \geq f_0(x^*)$ (Boyd & Vandenberghe, 2004).

2.5.1. Estructura de problemas de optimización

En general, consideramos familias o clases de problemas de optimización, que se caracterizan por formas particulares de las funciones objetivo y restricciones.

Problemas de mínimos cuadrados

Estos son problemas de optimización sin restricciones, y su función objetivo es una suma de los cuadrados de los términos de la forma $a_i^T x - b_i$, y su estructura es:

$$\text{minimizar } f_0(x) = \|Ax - b\|_2^2 = \sum_{i=1}^k (a_i^T x - b_i)^2 \quad (2.15)$$

donde $A \in \mathbf{R}^{k \times n}$ (con $k \geq n$), a_i^T son las filas de A , y el vector $x \in \mathbf{R}^n$, es la variable de optimización

Problemas de programación lineal

Otra clase importante de problemas de optimización es programación lineal, en la que las funciones de restricciones objetivos y todos son lineales:

$$\begin{aligned} & \text{minimizar } c^T x \\ & \text{sujeto a } a_i^T x \leq b_i, \quad i = 1, \dots, m \end{aligned} \quad (2.16)$$

donde los vectores $c, a_1, \dots, a_m \in \mathbf{R}^n$ y escalar $b_1, \dots, b_m \in \mathbf{R}$ son parámetros del problema que especifican las funciones objetivo y restricciones.

Optimización convexa

Un problema de optimización convexa es una de las formas:

CAPÍTULO 2. MARCO TEÓRICO

$$\begin{aligned} & \text{minimizar } f_0(x) \\ & \text{sujeto a } f_i(x) \leq b_i, \quad i = 1, \dots, m \end{aligned} \quad (2.17)$$

Donde: las funciones $f_0, \dots, f_m: \mathbf{R}^n \rightarrow \mathbf{R}$ son convexas, *i.e.*, satisface

$$f_i(\alpha x + \beta y) \leq \alpha f_i(x) + \beta f_i(y) \quad (2.18)$$

para todo $x, y \in \mathbf{R}^n$ y todo $\alpha, \beta \in \mathbf{R}^n$ con $\alpha + \beta = 1, \alpha \geq 0, \beta \geq 0$. Los problemas de mínimos cuadrados (2.11) y problemas programación lineal (2.12) son un caso especial de problemas de optimización convexa (2.13).

Optimización no lineal

La optimización no lineal (o programación no lineal) es el término utilizado para describir un problema de optimización cuando las funciones objetivos o restricciones no son lineales, pero no se sabe que son convexas.

Optimización local

En optimización local, el compromiso es renunciar a la búsqueda de la x óptima, lo que minimiza el objetivo sobre todos los puntos factibles. Lo que significa que minimiza la función objetivo entre puntos factibles que están cerca de él, pero está no garantiza tener un valor objetivo más bajo que todos los otros puntos factibles. Una gran parte de la investigación sobre la programación no lineal en general se ha centrado en métodos de optimización local.

Existen desventajas de los métodos de optimización local, más allá de (posiblemente) no hallar la verdadera solución, óptima global. El punto de partida inicial es crítico, y puede afectar el valor objetivo de la solución local.

El uso de un método de optimización local es más complicado que la solución de un problema de mínimos cuadrados, programa lineal, o problema de optimización convexa. Se trata de la experimentación con la elección del algoritmo, el ajuste de parámetros del algoritmo, y el hallazgo de una buena y suficiente aproximación inicial.

Optimización global

En la optimización global, se encuentra la verdadera solución del problema de optimización (2.10); el compromiso es eficiencia.

La optimización global se utiliza para los problemas con un pequeño número de variables, donde el tiempo de cálculo no es crítico, y el valor del hallazgo de la verdadera solución global es muy alto.

El costo es el tiempo de cálculo, que puede ser muy grande, incluso para un número relativamente pequeño de parámetros. Pero puede valer la pena en los casos en que el

CAPÍTULO 2. MARCO TEÓRICO

valor de la certificación de eficiencia es alto, o el costo de equivocarse acerca de la fiabilidad o la seguridad es alto. (Nocedal, Wright, Wright, & Robinson, 2006)

2.5.2. Algoritmo de optimización

No hay único método para la solución de todos los problemas de optimización. Por lo tanto, un número importante de métodos se han desarrollado para resolver diferentes tipos de problemas (Astolfi, 2010).

Vamos a enumerar los métodos de resolución de los problemas de optimización más utilizados

Programación lineal

Para muchos problemas de programación lineal, el método simplex sigue siendo el mejor. Sin embargo, se han introducido mejoras diversas, como el método simplex revisado, el dual, o los métodos primal–dual (Castillo, Conejo, Pedregal, García, & Alguacil, 2002).

Programación no lineal sin restricciones

Estos se clasifican en dos categorías:

1. Los que emplean información sobre las derivadas. Estos métodos operan directamente sobre la condición necesaria de optimalidad.

$$f'(x^*) = 0 \quad (2.19)$$

Para obtener x^* , que es la solución buscada, como ejemplos están: método de Newton, método quasi-Newton o de la secante.

2. Los que emplean solamente evaluaciones de la función objetivo. Estos algoritmos interpolan iterativamente la función objetivo y derivan fórmulas para calcular el mínimo de la función interpolada. Estos mínimos generan una sucesión que converge a la solución buscada, por ejemplo los de la búsqueda lineal mediante interpolación cuadrática. (Castillo, et al, 2002).

Algoritmos de optimización no lineal con restricciones

Estos problemas se pueden resolver usando fundamentalmente las siguientes familias de métodos:

1. Métodos duales: que resuelven el problema dual en lugar del primal, ósea resuelven dos optimizaciones en el mismo problema.

CAPÍTULO 2. MARCO TEÓRICO

2. Métodos de penalizaciones: que transforman el problema con restricciones en una sucesión de problemas sin restricciones. Las restricciones se introducen en la función objetivo mediante la llamada función de penalización–barrera y un adecuado parámetro de penalización. Un ejemplo es el método de Punto Interior (*Interior point* por sus siglas en inglés)
3. Método de los multiplicadores o del Lagrangiano aumentado: éste es un método de penalizaciones (cuadráticas), en el que en lugar de incorporar las restricciones en la función objetivo se añaden a la función Lagrangiana.
4. Métodos de direcciones factibles: esta clase de métodos extiende los algoritmos de direcciones de descenso al caso de problemas con restricciones. En este contexto se fuerza a las direcciones de búsqueda, además de ser de descenso, a que den lugar a desplazamientos dentro de la región factible.
5. Métodos de programación cuadrática secuencial (SQP por sus siglas en inglés): que resuelven una sucesión de problemas cuadráticos que aproximan iterativamente al problema original (Castillo et al., 2002). El método permite que para imitar el método de Newton para la optimización con restricciones tal como se hace para optimización sin restricciones. En cada iteración se realiza una aproximación de la Hessian de la función lagrangiana utilizando un método de actualización cuasi-Newton. Este es entonces utilizado para generar un subproblema de programación cuadrática (QP por sus siglas en inglés) cuya solución se utiliza para formar una dirección de búsqueda (Nocedal et al., 2006).

Un ejemplo de este método es Set Activo: método que utiliza SQP pero como complementariedad utiliza un conjunto activo $A(x^*)$ que hace que sea más fácil para los algoritmos llegar rápidamente a la solución x^* .

Como se indicó el SQP se basa en encontrar un subproblema QP para buscar la dirección, basado en la aproximación cuadrática de la función de Lagrange

$$L(x, \lambda) = f(x) + \sum_{i=1}^n \lambda_i g_i(x) \quad (2.20)$$

La implementación consiste en 3 principales pasos:

- a) Actualización de la matriz Hessian
- b) Solución por programación cuadrática
- c) Búsqueda de la línea y la función mérito

CAPÍTULO 3

3 METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

3.1. INTRODUCCIÓN

Este capítulo presenta la metodología de diseño del modelo y del optimizador para el circuito de molienda de cemento de UCEM-Planta Guapán. La base de datos registrada en las hojas de Excel en Laboratorio y en el Panel Central proveen de información de variables de operación y de calidad, comprendidas entre las fechas de marzo de 2014 a septiembre de 2015. Estos datos son registrados de forma manual, considerando períodos de muestreo de 1 hora para las variables de operación y de 2 horas para las variables de calidad.

Para evitar procesar valores con errores desde el Excel, se utilizan herramientas en MATLAB para filtrar los datos y eliminar valores atípicos (*outliers*) y nulos. La referencia (L. I. Minchala, et al.,2016) presenta una metodología de preprocesamiento de datos para generación de modelos estadísticos.

El análisis de las variables de calidad y operación se basa en determinar los estadísticos descriptivos, la correlación entre variables de entrada y los de salida, la búsqueda de datos de operaciones no estables, todo esto con la finalidad de que el conjunto de datos permita obtener resultados coherentes en la optimización .

3.2. VARIABLES DE ESTUDIO

La Figura 3.1 muestra un diagrama general del proceso de molienda de cemento en UCEM-Planta Guapán. Las variables de proceso se registran en un PLC Siemens S7-400, una conexión a panel de control sobre Profibus a un PC industrial o HMI donde corre una aplicación en WINCC. El registro de las variables en el sistema SCADA se realiza con una frecuencia de 1 segundo. Estos registros almacenan la información de los 3 últimos meses en una base de datos.

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

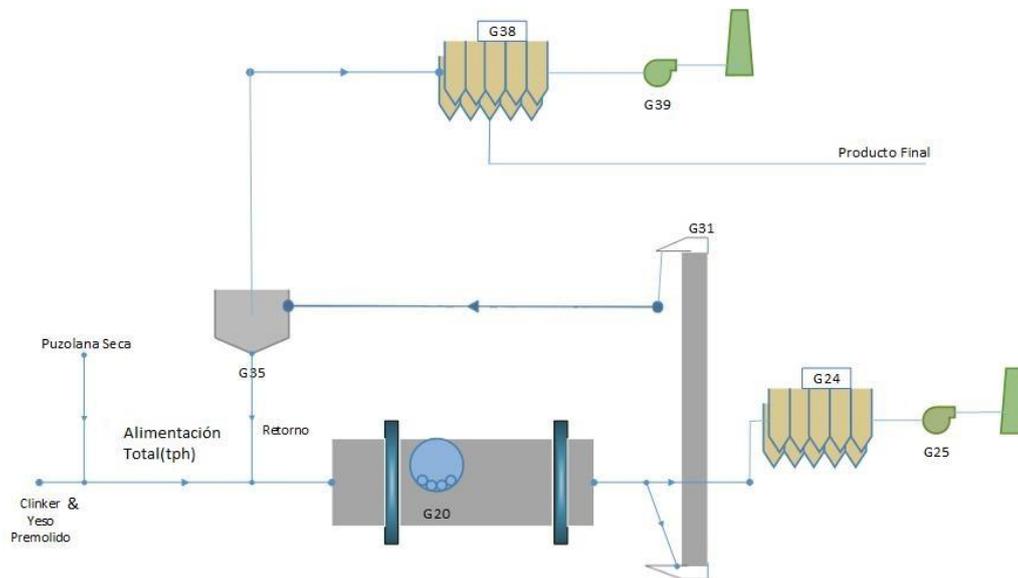


Figura 3.1 Proceso de molienda de UCEM-Planta Guapán

La Figura 3.1 muestra los 3 equipos fundamentales en el circuito de molienda de UCEM-Planta Guapán , que son:

- Molino de bolas (G20)
- Separador de aire modelo OSEPA (G35)
- Filtro con ventilador de extracción de finos o producto (G39)

En el G35 se lleva a cabo la separación del flujo de ingreso proveniente del elevador G31 en 2 flujos, el flujo de retorno al molino y el flujo de producto terminado al colector de polvo G38. Una variable típica que indica estabilidad del proceso es el flujo de retorno. Las variables de operación son las velocidades de los rotores G35 y G39, además de la alimentación de material al molino.

Para establecer que tan difícil resulta moler la mezcla que ingresa al G20, es importante conocer el silicato tricálcico (C3S o alita) del clinker, que nos permite establecer un rango para la molturabilidad.

El consumo específico se calcula utilizando la ecuación (3.1) que está en función de la corriente del motor del molino (IG20).

$$\text{consumo específico} = \frac{\text{Energía}}{\text{Producción}} = \frac{V IG20 \text{ Cos}\phi \sqrt{3} / t}{\text{Producción}} \quad (3.1)$$

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

donde: E es Energía en kilovatios hora, V es Voltaje del motor, I es Corriente del motor (IG20), $\cos\phi$ es el desfase en el voltaje, t es tiempo en horas

El flujo de producción no posee un sistema de medición. Debido a esto, es necesario estimar este flujo utilizando la Ecuación (3.2). Su unidad es toneladas por hora (tph).

$$\text{Producción} = fG31 - \text{flujo de retorno} \quad (3.2)$$

En donde $fG31$ representa el flujo que el elevador transporta hacia el G35 que está vinculado con la energía de su motor y su ecuación está representada por (3.3).

$$fG31 = \frac{467 EG31}{h k} \quad (3.3)$$

donde: $fG31$ representa el flujo de carga (tph), $EG31$ representa la energía del motor del elevador G31 (kwh), h la altura(22.73m), k es una constante por el tipo de material (2.1103).

La carga circulatoria (CL, por sus siglas en inglés), define el número de veces que el material circula por el sistema de molienda, se calcula como lo muestra la ecuación (3.4)

$$CL = \frac{B_0 + B_1}{B_0} \quad (3.4)$$

donde: B_0 es el flujo de alimentación al molino, B_1 es el flujo de retorno y CL es la carga circulatoria.

Para obtener un producto que cumpla con las especificaciones de calidad que se detallan en la sección 1.3, las variables a considerar son el Blaine y el retenido (ret45).

Para obtener un cemento en el cual su dosificación se maximice el nivel de puzolana, es importante disponer de la composición en el producto final del óxido de calcio (CaO) que es un parámetro de control de calidad reportada en las hojas Excel y con alta correlación con el porcentaje de puzolana.

La Figura 3.2 muestra un esquema de flujos con las variables mencionadas anteriormente.

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

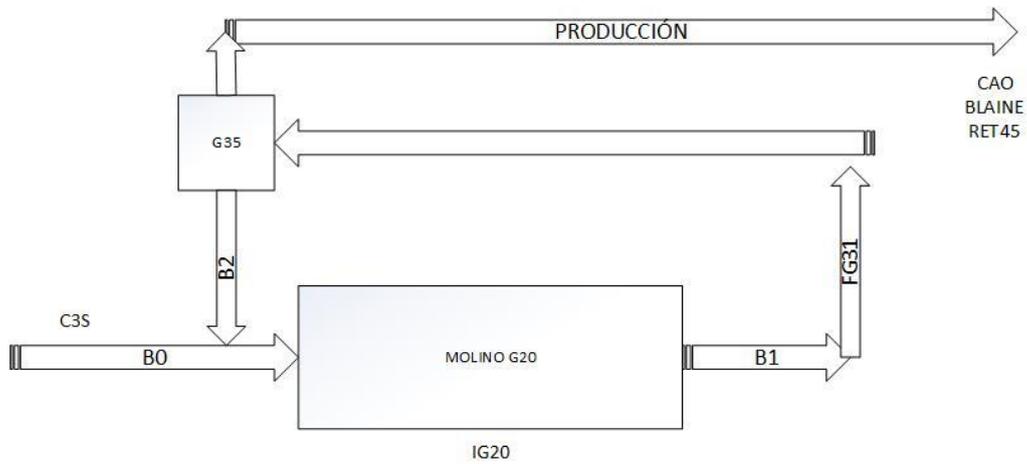


Fig.3.2 Esquema de flujos con variables

3.3. PROCESAMIENTO DE LA INFORMACIÓN DE LA BASE DE DATOS

La base de datos posee un registro de 13392 muestras. La Figura 3.3 muestra la metodología utilizada y el criterio de eliminación de *outliers* del conjunto de datos original.

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

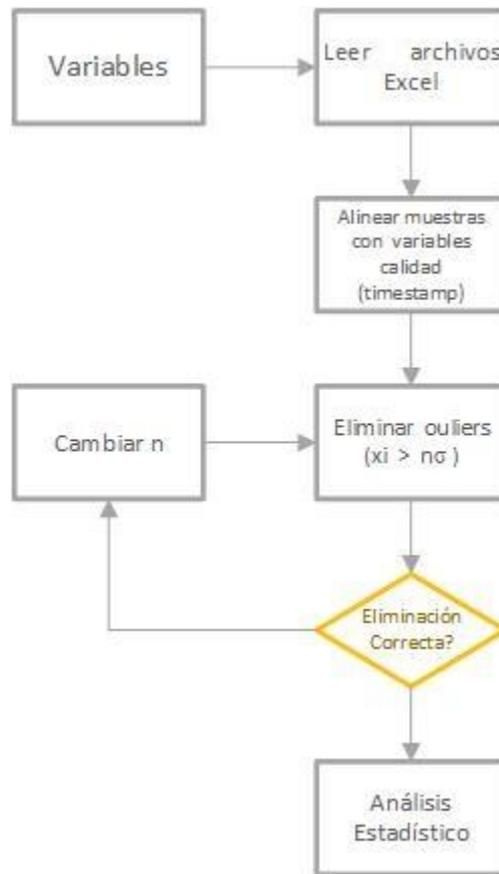


Figura 3.3 Metodología utilizada para el análisis de la información de la base de datos

Las Tabla 3.1 muestra los estadísticos descriptivos de las variables de calidad y de proceso utilizados en el proceso de modelación. Es importante resaltar que para el cálculo de los estadísticos se eliminaron los datos atípicos cuyo valor excede de 1.5 desviaciones estándar. Este valor se obtuvo después de analizar si la eliminación fue correcta con la gráfica de boxplot, tal como lo indica la Figura 3.6.

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

Tabla 3.1 Descripción de las variables

| Nombre | Descripción | Unidad | Valor Mínimo | Valor Máximo | Desviación Estándar | Valor Medio |
|----------|-----------------------|-------------------|--------------|--------------|---------------------|-------------|
| C3S | C3S | % | 52.49 | 78.60 | 5.46 | 66.34 |
| Blaine | Finesa Blaine | g/cm ² | 3656.06 | 4537.84 | 159.72 | 4107.80 |
| ret45 | Retenido malla (45um) | % | 2.00 | 5.90 | 0.83 | 3.85 |
| CAO | Oxido de Calcio | % | 45.94 | 57.20 | 2.19 | 51.97 |
| IG20 | Corriente G20 | A | 299.00 | 330.00 | 6.08 | 314.50 |
| ALIMENTA | Alimentación | tph | 50.70 | 80.30 | 4.60 | 66.39 |
| IG31 | Corriente G31 | A | 27.00 | 62.00 | 2.83 | 41.05 |
| RETORNO | Flujo Retorno | tph | 40.00 | 128.00 | 18.87 | 83.00 |

La Figura 3.4 presenta las gráficas de las variables de proceso y de calidad. Notamos que el número de muestras es menor al del conjunto de datos original debido a que fueron eliminados los valores nulos y los valores atípicos.

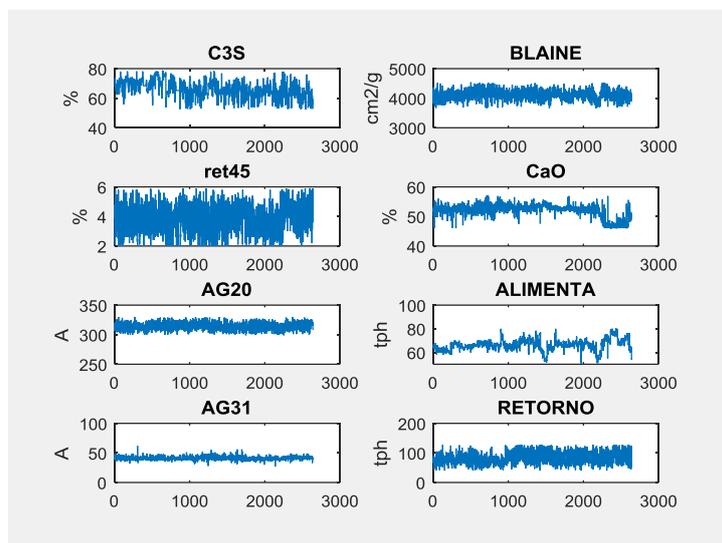


Figura 3.4 Curvas de variables de análisis

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

La Figura 3.5 muestra las gráficas de capacidad de proceso de las variables de análisis. Estos gráficos muestran la probabilidad de que la variable este en un rango específico.

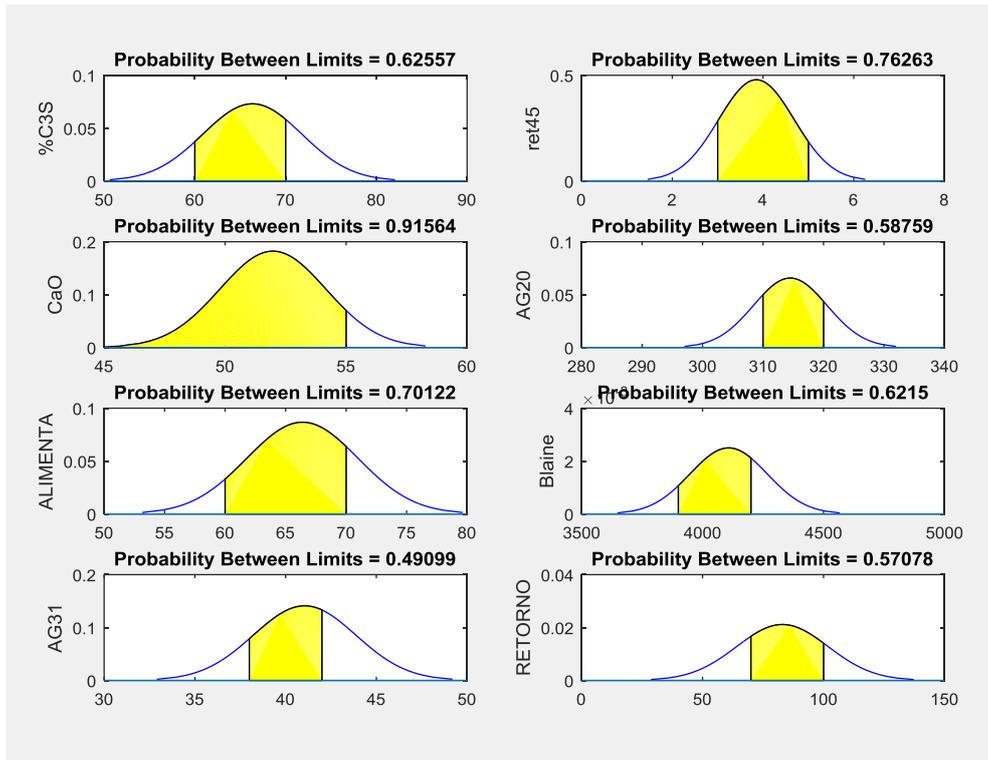


Figura 3.5 Gráficas de capacidad de variables de análisis.

La Figura 3.6 muestra la gráfica boxplot que representa el conjunto de datos con valores atípicos y sin valores atípicos, de acuerdo a la metodología explicada en la Figura 3.3 se probó quitando valores con una desviación estándar mayor a 2.5, 2 y 1.5, el mejor resultado que se obtuvo fué con 1.5 y es el gráfico de boxplot de la Figura. Las variables ahí representadas con números son:

| | | | |
|---|--------|---|----------|
| 1 | C3S | 5 | AG20 |
| 2 | Blaine | 6 | Alimenta |
| 3 | ret45 | 7 | AG31 |
| 4 | CaO | 8 | Retorno |

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

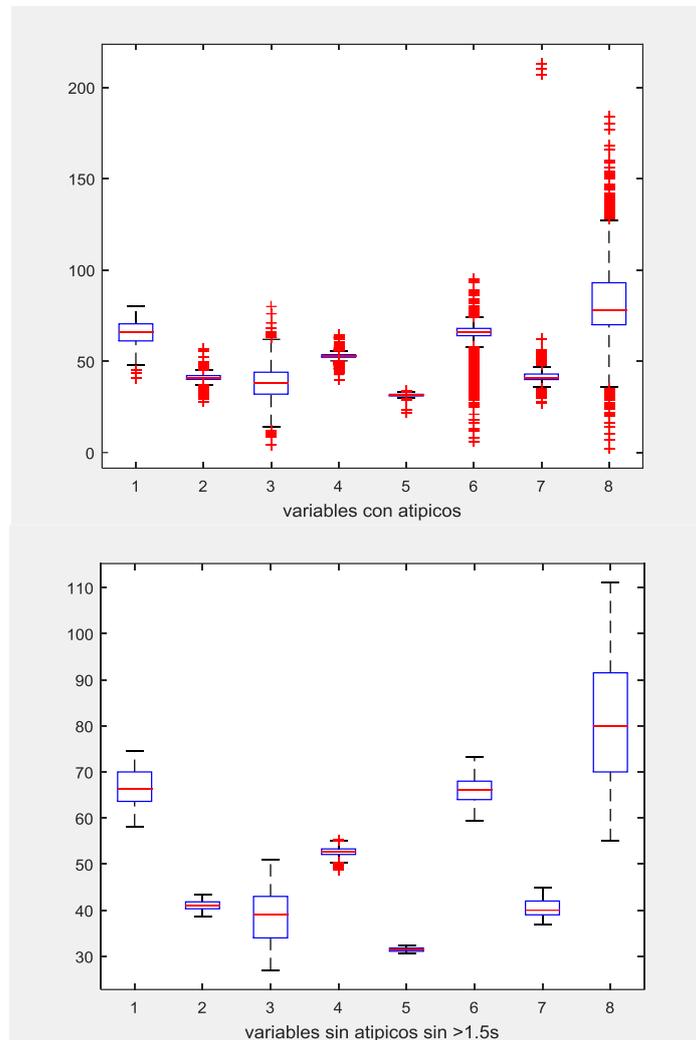


Figura 3.6 Gráfica de boxplot con valores atípicos y sin atípicos $> 1,5$ de desviación estándar

Cabe señalar que las variables de velocidad de G35 y velocidad de G39 fueron tomadas en cuenta en primera instancia, pero dichas variables sirven para el control de la operación y el enfoque de este proyecto no tiene ese alcance por lo que se desecharon para la modelización.

3.4. ANÁLISIS DE CORRELACIÓN

Esta sección presenta un análisis de correlación entre las variables explicadas en la Tabla 3.1 y su correspondencia mostrada en la Tabla 3.2.

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

Tabla 3.2 Correspondencia de Variables

| # | Variable |
|----|----------|
| x1 | IG20 |
| x2 | IG31 |
| x3 | ALIMENTA |
| x4 | Blaine |
| x5 | C3S |
| x6 | CAO |
| X7 | ret45 |
| X8 | RETORNO |

La Tabla 3.3 muestra la matriz de correlación R que es una matriz cuadrada de $k \times k$ (siendo k el número de variables de regresión) constituida por los coeficientes de correlación, presentadas en la sección 2.2.1, de cada pareja de variables de regresión. La matriz R es simétrica, con unos en la diagonal y los coeficientes de correlación lineal r_{ij} en las posiciones no diagonales. Su ecuación es (3.5)

$$R = \begin{bmatrix} 1 & r_{12} & \dots & r_{1k} \\ r_{12} & 1 & \dots & r_{2k} \\ \dots & \dots & \dots & \dots \\ r_{k1} & r_{k2} & \dots & 1 \end{bmatrix} \quad (3.5)$$

Siendo R : matriz de correlación y r_{ij} el índice de correlación entre las variables

Tabla 3. 3 Matriz de Correlación de entrada y de salida

| | | | | | | | | | | | | | | | | | | | | |
|----|-------------------|--------|--------|----|--------|---|------------------|-------|----|--------|----|--------|---|-------|----|--------|---|-------|--|--|
| | x5 | x3 | x4 | x7 | x6 | | x1 | x2 | x8 | | | | | | | | | | | |
| x5 | 1.000 | 0.013 | 0.160 | 0 | 0.137 | <table border="1"> <tbody> <tr> <td>x1</td> <td>1.000</td> <td>0</td> <td>-0.077</td> </tr> <tr> <td>x2</td> <td>-0.004</td> <td>1</td> <td>0.342</td> </tr> <tr> <td>x8</td> <td>-0.077</td> <td>0</td> <td>1.000</td> </tr> </tbody> </table> | x1 | 1.000 | 0 | -0.077 | x2 | -0.004 | 1 | 0.342 | x8 | -0.077 | 0 | 1.000 | | |
| x1 | 1.000 | 0 | -0.077 | | | | | | | | | | | | | | | | | |
| x2 | -0.004 | 1 | 0.342 | | | | | | | | | | | | | | | | | |
| x8 | -0.077 | 0 | 1.000 | | | | | | | | | | | | | | | | | |
| x3 | 0.013 | 1.000 | 0.213 | 0 | -0.472 | | | | | | | | | | | | | | | |
| x4 | 0.160 | 0.213 | 1.000 | 0 | -0.145 | | | | | | | | | | | | | | | |
| x7 | -0.034 | 0.105 | -0.217 | 1 | -0.106 | | | | | | | | | | | | | | | |
| x6 | 0.137 | -0.472 | -0.145 | 0 | 1.000 | | | | | | | | | | | | | | | |
| | Variables Entrada | | | | | | Variables Salida | | | | | | | | | | | | | |

Podemos observar en la matriz de variables de entrada de la Tabla 3.3 que la variable x3 con x6 tiene la correlación más fuerte con R igual a -0.47 y al ser menor su valor absoluto a 0.6 no cumpliría con la característica de colinealidad, tal como se explicó en la sección 2.2.2. Para las variable que forman la salida vemos en la matriz correspondiente que la correlación más fuerte es 0.342 entre x2 y x8.

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

En (López Pineda, 2013) se define el parámetro de condición k de R , cuya expresión es $k = \frac{\lambda_{\max}}{\lambda_{\min}}$. En donde λ_{\max} y λ_{\min} son los valores máximo y mínimo del vector de eigenvalores de R . El criterio es que si $k < 100$ significa que no hay problema de multicolinealidad. Si los valores están entre 100 y 1000 puede decirse que existe una multicolinealidad de moderada a fuerte. Sin embargo si el valor de k es mayor a 1000 significa que existen variables fuertemente correlacionadas de forma lineal. Para nuestro caso $k=4.4281$. Como conclusión de las matrices de entrada y de salida es que no existe colinealidad entre las variables por lo que no pueden ser sacadas del modelo, sin poder reducir así el número de entradas.

La Figura 3.7 muestra la gráfica de dispersión entre las variables de entrada y la gráfica correspondiente a las de salida, la correlación mencionada R entre x_3 y x_6 y la de salida x_2 y x_8 . podemos visualmente confirmarlo.

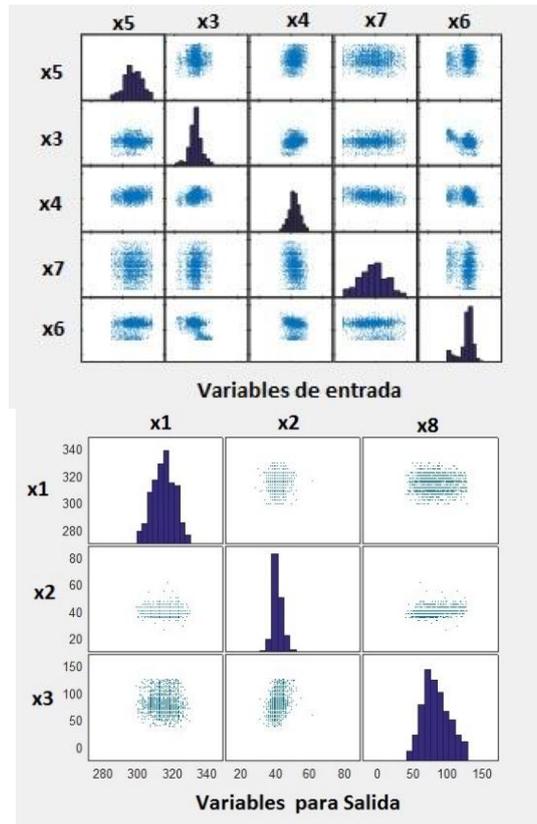


Figura 3.7 Gráfica de dispersión de las variables entrada – salida

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

3.5. MODELIZACIÓN

Esta sección presenta las dos modelizaciones de regresión polinómica para el sistema de optimización y las metodologías utilizadas en el modelo principal de regresión múltiple, ANN, y ANFIS.

Los modelos de regresión polinómica sirven para mostrar información en el sistema y son:

Modelo consumo específico - producción

Este modelo con una entrada y una salida, proporciona la estimación de la producción una vez hallado el punto de consumo específico óptimo, se construye el modelo como se explico en la sección 2.2.2 , la ecuación y el coeficiente de determinación encontrado R^2 es 0.9857.

$$y = -0.0002x^3 + 0.0408x^2 - 3.5732x + 135.17 \quad (3.6)$$

donde: y es el consumo específico en kwh/t, y x la producción en tph.

Modelo consumo específico - retorno

Este modelo con una entrada y una salida, proporciona la estimación del retorno una vez hallado el punto de consumo específico óptimo. Con el conjunto de datos se realizó una regresión polinómica cuyo resultado esta expresado en la ecuación (3.7) con un coeficiente de determinación R^2 es 0.8207

$$y = -0.0594x^2 + 5.9093x - 30.459 \quad (3.7)$$

donde: x es el consumo específico en kwh/t, y y el retorno en tph.

Modelo principal

El modelo representado en la Figura 3.8 muestra las entradas y la salida del modelo a optimizar, tiene cinco variables independientes y una salida que es el indicador de kilovatio hora por tonelada (kwh/t) o consumo específico. Debido a que no se dispone de un sistema de medición directa para esta variable se utiliza la corriente del molino G20, la corriente del elevador G31 y el flujo del retorno, la explicación del cálculo del indicador de consumo específico se presenta en la sección 3 con las ecuaciones (3.1), (3.2) y (3.3). La modelización de esta variable permite obtener el conjunto completo de datos para entrenar a los modelos.

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR



Figura 3.8 Estructura del modelo

La selección de estas variables se basa en un criterio del conocimiento del proceso, en el que cada variable escogida incida en la operación y en la calidad del producto, como también del indicador energético que es la variable objetivo a minimizar.

El conjunto de datos se divide en 70% para modelar y 30% para probar el modelo. El conjunto de datos de prueba nos permite comprobar la capacidad de generalización del sistema de inferencia resultante.

3.5.1 Modelos de regresión múltiple

La metodología de diseño de regresión múltiple para las variables de análisis se presenta en la Figura 3.9.

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

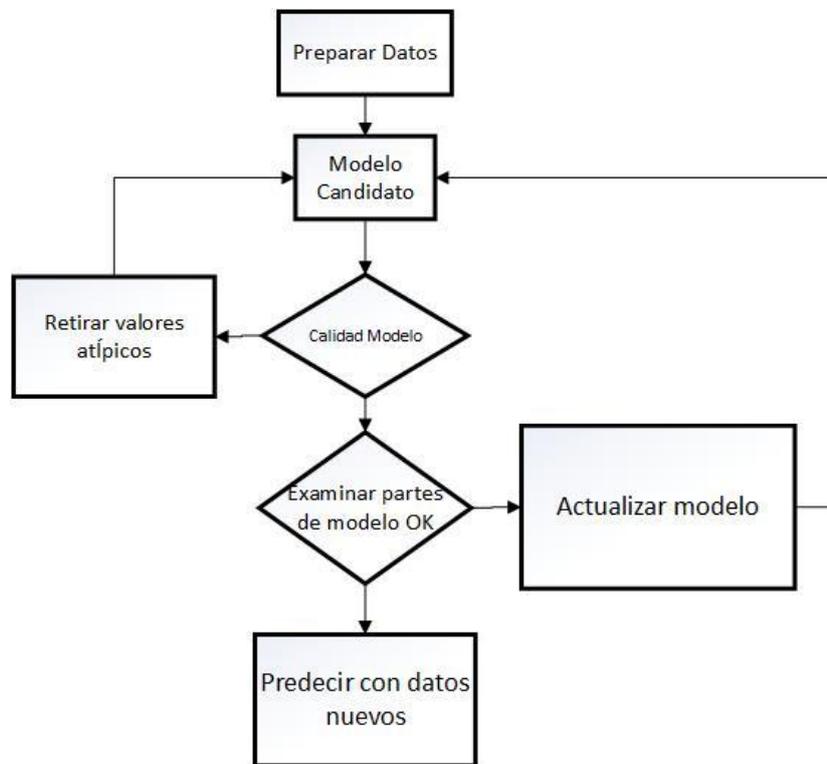


Figura 3.9 Metodología utilizada para modelos de regresión

La Figura 3.10 muestra la dispersión de cada una de las variables de entrada del modelo con respecto al consumo específico. La Figura 3.11 muestra la tendencia de cada una de estas variables con respecto al consumo específico, esta tendencia nos ayuda a entender por ejemplo, que al subir el C3S el consumo energético baja.

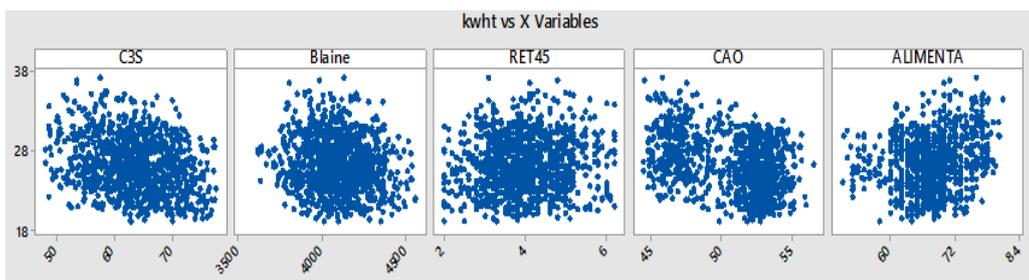


Figura 3.10 Dispersión entre kwh/t y variables de ingreso

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

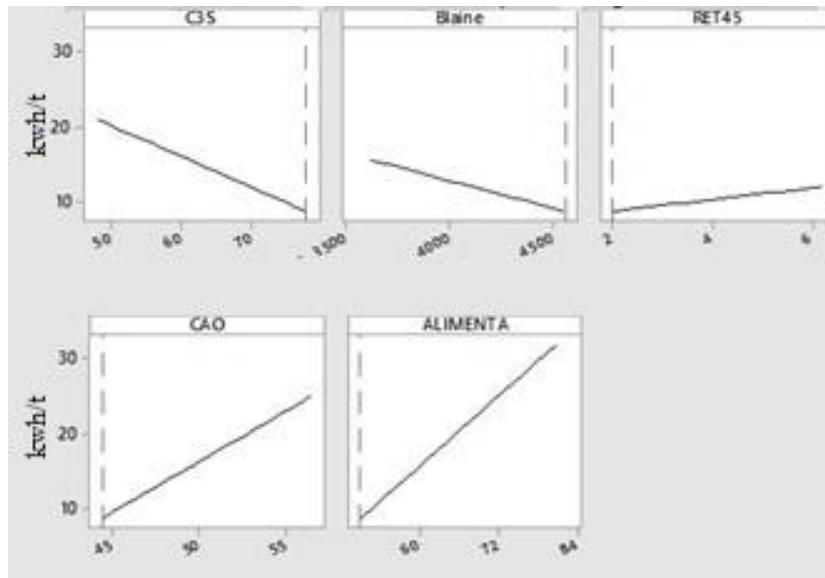


Figura 3.11 Tendencia de ingresos vs kwh/t

Reescribiendo la ecuación de regresión no lineal mostrada en la sección 2.2.2 y en una forma polinomial el modelo de regresión es:

$$y_i = b_0 + \sum_{k=1}^k b_k f_k(x_{i1}, x_{i2}, \dots, x_{ip}), \quad \text{con } i = 1, \dots, n \quad (3.8)$$

donde y es la variable modelada (kwh/t), i es el número de variables de entrada, k es el número de parámetro de la regresión, x_i y y_i son las variables de regresión, y los b_i son los coeficientes de regresión (Neter, J., M. H. Kutner, C. J. Nachtsheim, 1996) (Seber, 1989).

El resultado del modelo utilizando mínimos cuadrados con la herramienta de regresión setpwise de MATLAB y la metodología de la Figura 19 es:

$$y = 232.8 - 2.912x_1 - 0.0631x_2 + 1.34x_3 - 2.465x_4 + 2.696x_5 + 0.000162x_1x_2 + 0.02733x_1x_4 + 0.01068x_1x_5 + 0.000976x_2x_4 + 0.0925x_3x_4 - 0.0915x_3x_5 - 0.05796x_4x_5 + 0.2341x_4 + 0.1319x_5 \quad (3.9)$$

El ajuste del modelo es: $R^2 = 0.3064$

La Figura 3.12 muestra la prueba con el 30% de los datos.

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

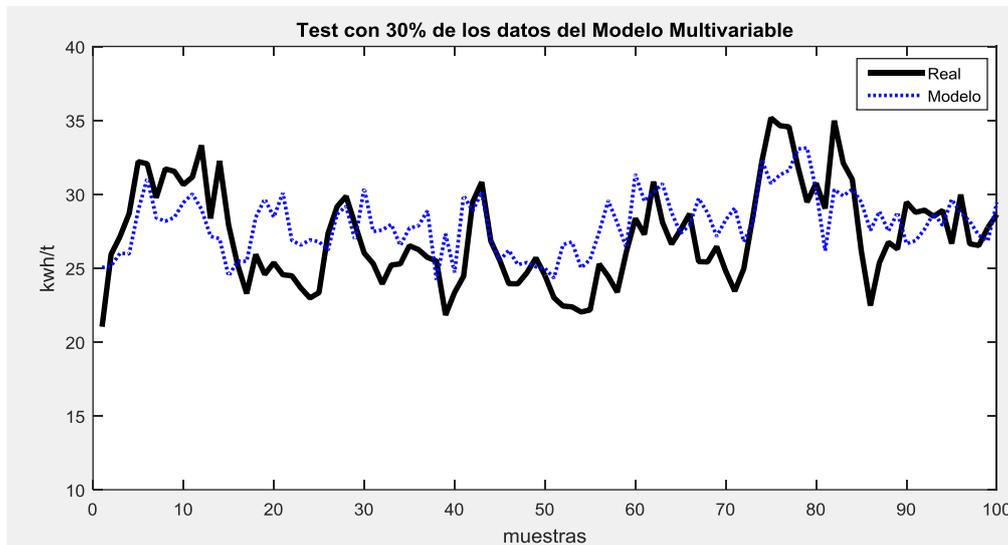


Figura 3.12 Prueba del modelo de regresión

La validación de modelos busca detectar si una distribución de probabilidades del error supuesta es congruente con un conjunto de datos dado. Para esto se utilizan pruebas de bondad de ajuste tales como la prueba de Kolmogorov–Smirnov. Sea X_1, \dots, X_n , los resultados obtenidos a partir de una muestra aleatoria de la cual se ha asumido que su distribución de probabilidades está determinada por la función de probabilidad $P_o(X)$, se plantea la hipótesis nula $H_0 : F(X) = F_o(X)$, especificada de manera completa con respecto a todos los parámetros (Sánchez Christian, Yungaicela Noé, 2015).

La evaluación de este supuesto se hace sobre los datos obtenidos a partir de una muestra de tamaño n . H_0 es rechazada si existe una diferencia significativa entre lo observado y lo esperado (Vera Lizcano, 2015). Con respecto a nuestro modelo aplicando esta prueba en MATLAB del error es igual a 1 lo que significa que la distribución de la muestra del error es normal, ya que un valor de 1 en el estadístico F no permite rechazar la hipótesis nula, por lo que el error del modelo pasa la prueba de normalidad.

La gráfica de la función de distribución acumulada (CDF, *por sus siglas en inglés*) del error se muestra en la Figura 3.13, en esta gráfica se compara una distribución normal con la distribución empírica de las muestras. También se muestra la probabilidad del error de estimación del modelo multivariable.

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

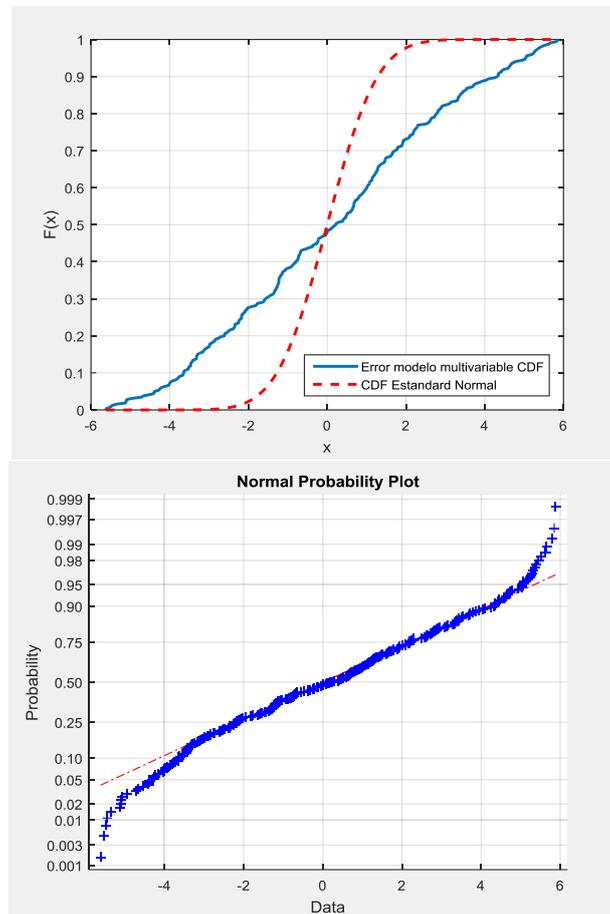


Figura 3.13 CFD y la probabilidad del error del modelo Multivariable

3.5.2 Modelización neuronal

El modelo ANN está determinado por la ecuación (2.9). La metodología de diseño del modelo con red neuronal se muestra en la Figura 3.14

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

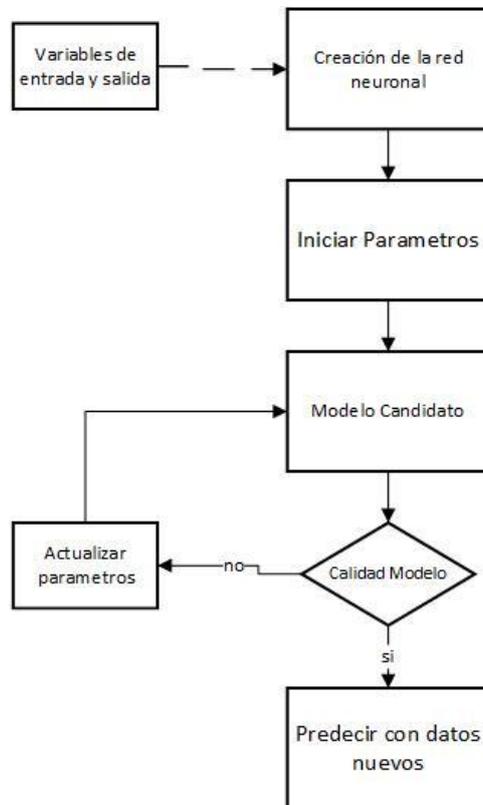


Figura 3.14 Metodología de modelación neuronal

Con la modelización de red neuronal con 20 neuronas se obtiene el mejor resultado y coeficiente de determinación es: $R^2 = .51031$

La Figura 3.15 muestra el resultado del modelo con redes neuronales.

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

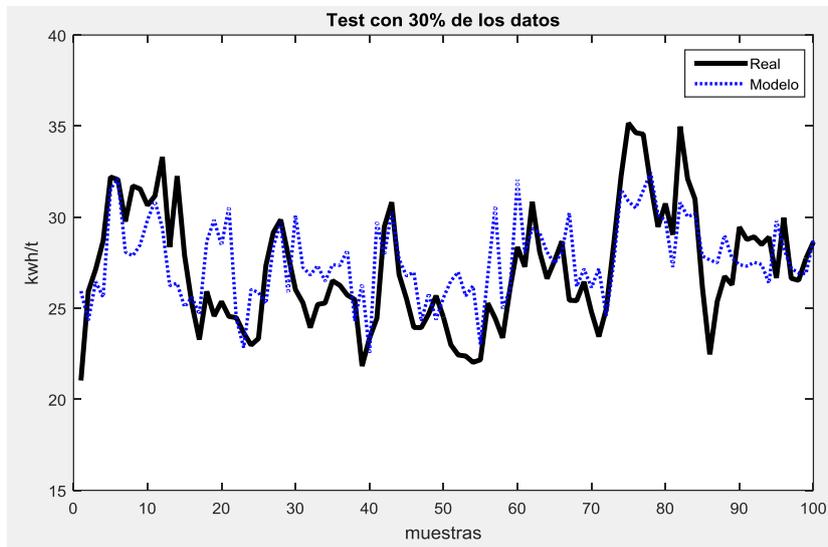


Figura 3.15 Resultado con el modelo ANN

Con la prueba de Kolmogorov-Smirnov del error la respuesta a la hipótesis nula es 1 lo que significa que la distribución de la muestra es normal, ya que un valor de 1 en el estadístico F no permite rechazar la hipótesis nula, por lo que el error del modelo pasa la prueba de normalidad, y la gráfica del CDF del error comparada con el CDF normal con la probabilidad del error se muestra en la Figura 3.16.

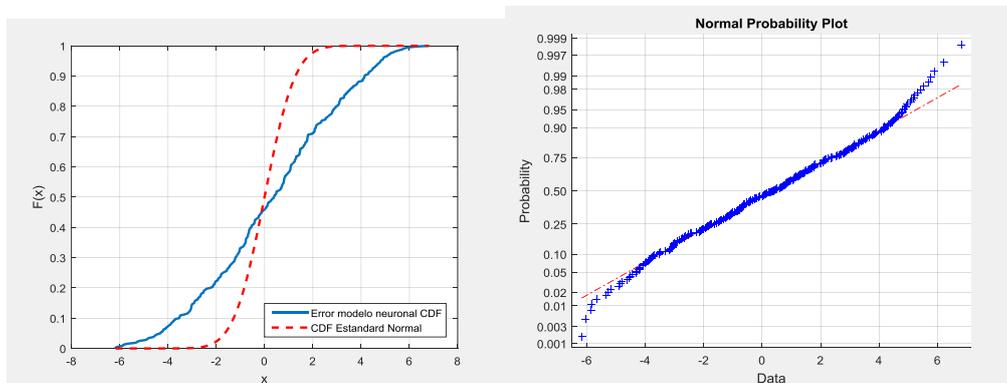


Figura 3.16 CDF y la probabilidad del error del modelo Neuronal

3.5.3 Modelización neurodifusa

La Figura 3.17 presenta la estructura del modelo neurodifuso (Ibrahim & Morcos, 2002). La metodología del diseño de los modelos ANFIS se muestra en la Figura 3.18

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

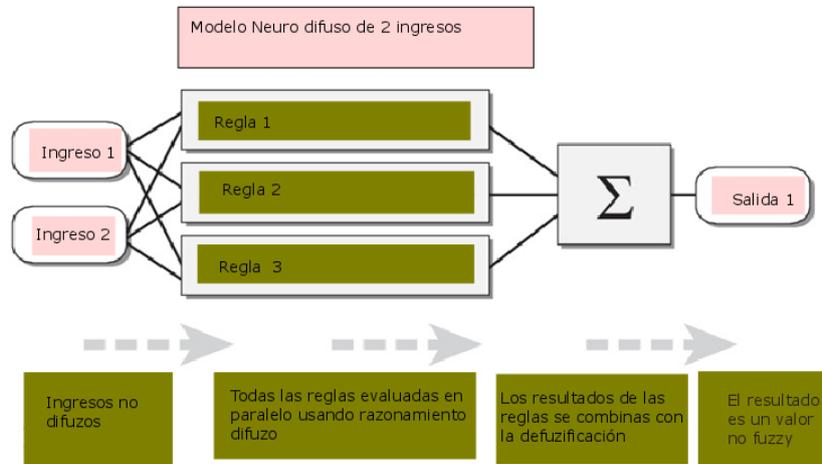


Figura 3.17 .Estructura modelo neurodifuso

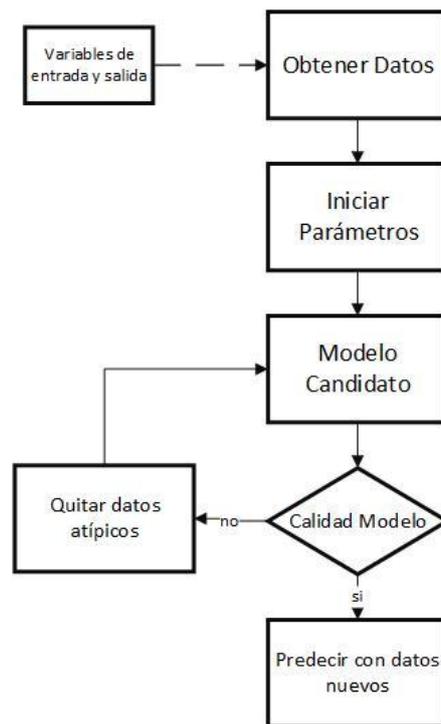


Figura 3.18 Metodología utilizada para modelos neurodifuso

Con la modelización neurodifuso se obtiene el mejor resultado coeficiente de determinación es: $R^2 = 0.4687$

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

La Figura 3.19 muestra la arquitectura del modelo neurodifuso que mejor resultado se obtuvo en la fase de entrenamiento con una función de membresía lineal tipo trimf.

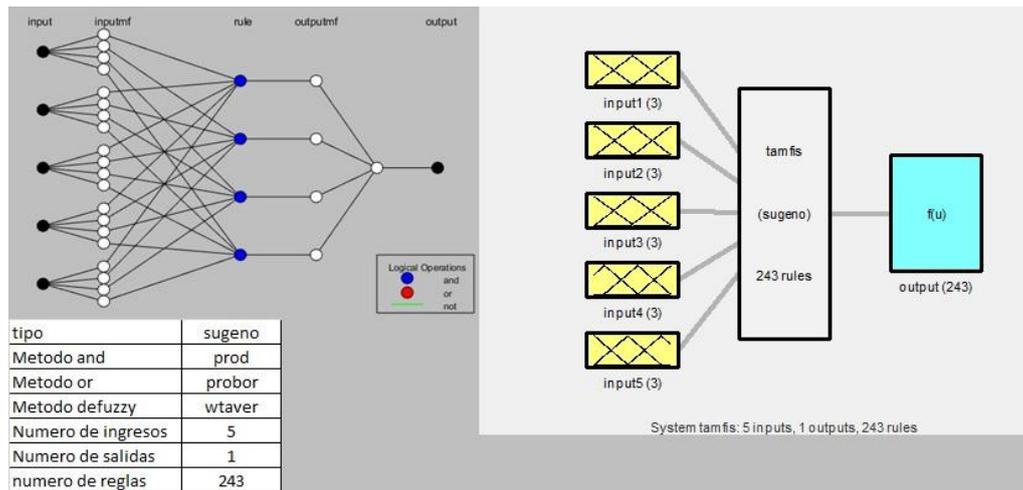


Figura 3.19 Arquitectura del modelo neurodifuso

El resultado con el modelo ANFIS se muestra en la Figura 3.20.

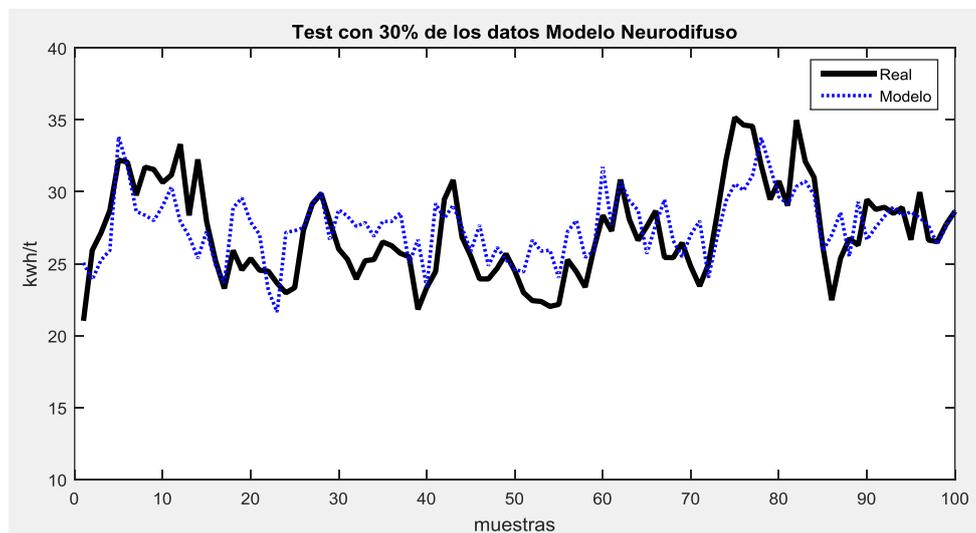


Figura 3.20 Resultado del modelo neurodifuso

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

Con la prueba de Kolmogorov-Smirnov del error la respuesta a la hipótesis nula es 1 lo que significa que la distribución de la muestra es normal, ya que un valor de 1 en el estadístico F no permite rechazar la hipótesis nula, por lo que el error del modelo pasa la prueba de normalidad, y la gráfica del CDF del error comparada con el CDF normal con la probabilidad del error se muestra en la Figura 3.21

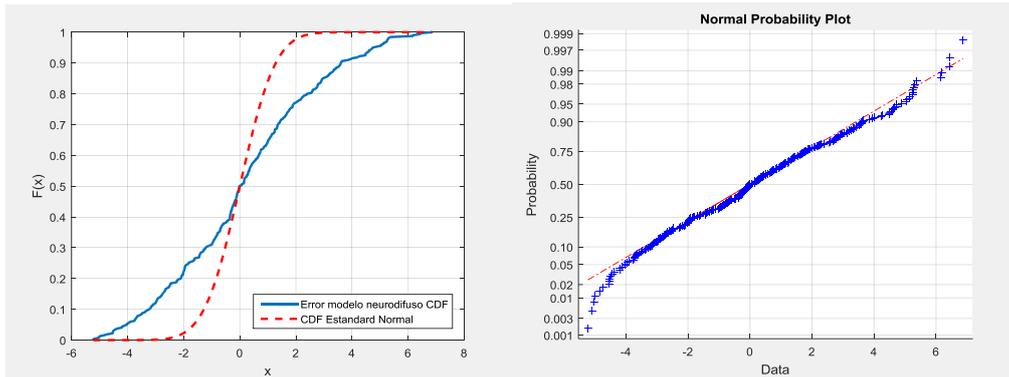


Figura 3.21 CDF y la probabilidad del error del modelo Neurodifuso

la Figura 3.22 muestra la comparación de respuesta de los 3 modelos con la variable real del 30% de los datos.

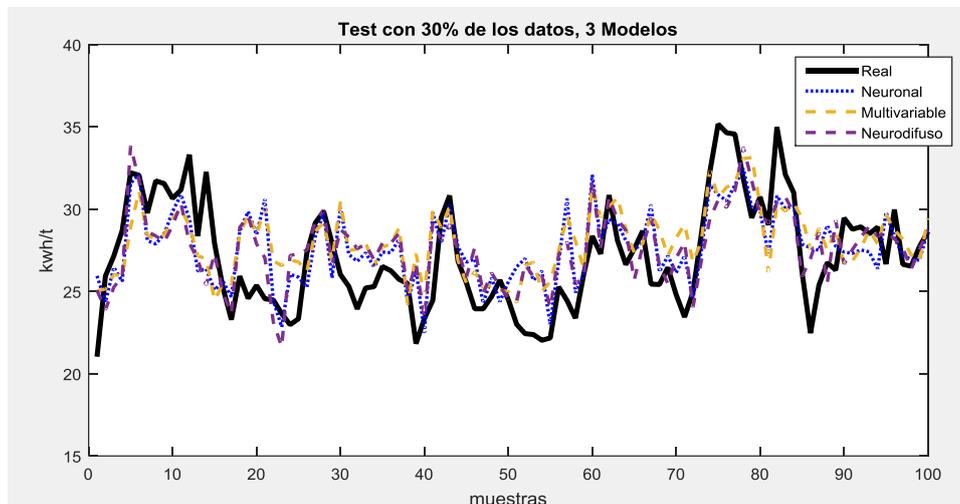


Figura 3.22 Resultado de los 3 modelos

La Figura 3.23 muestra CDF del error de los 3 modelos comparada con un CDF normal estándar.

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

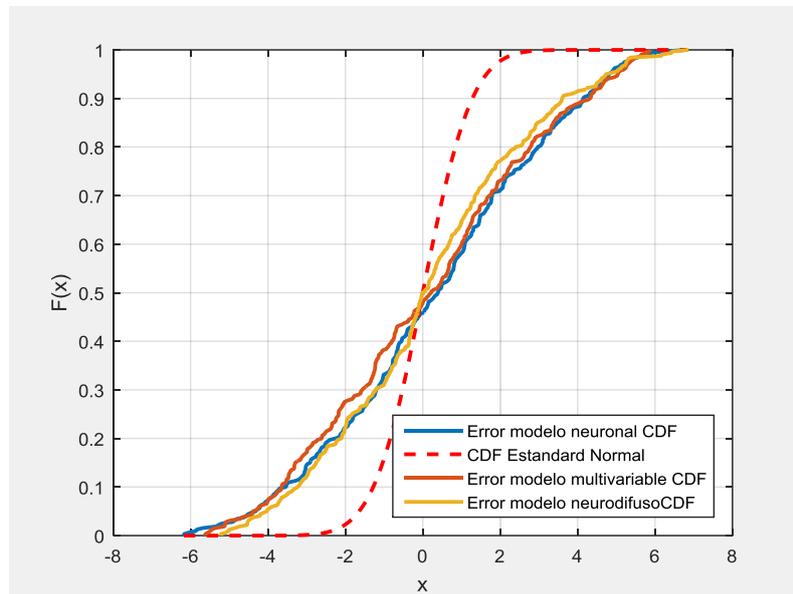


Figura 3.23 CDF de los 3 modelos

La Figura 3.22 muestra que los modelos de redes neuronales y multivariable tienen una dinámica parecida y son los que mejor aproximan a lo real.

La Figura 3.23 muestra que las CDF del error con el 30% de los datos, los 3 modelos se acercan a la CDF estándar normal, lo cual no indica que los modelos predicen con una distribución del error parecida y aceptable.

3.6. DISEÑO DEL OPTIMIZADOR

Los aspectos a considerar para el diseño de un optimizador son:

- Problema a optimizar
- Función a minimizar o función de costo
- Restricciones
- Método
- Sistema optimizador

Se definen a continuación los aspectos de diseño a considerarse en un problema de optimización.

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

Problema a optimizar

En la operación del molino no necesariamente se relaciona la energía utilizada para la producción de cemento, sino que se procura maximizar la producción cumpliendo con la calidad en lo referente a la fineza, el problema planteado en este proyecto de investigación es mantener al máximo la producción, pero minimizando la energía consumida por el motor del molino, esto se consigue minimizando el indicador de consumo específico (kwh/t).

La estructura del problema a optimizar es:

$$\min_x f(x) \quad \text{con } \{ lb \leq x \leq ub \} \quad (3.10)$$

donde: $f(x) = \theta(x)$, θ el modelo de consumo específico, x : las variables $[C3S, Blaine, Ret45, CAO, Alimenta]$, lb límites inferiores de x y ub límites superiores de x , restricciones de límites de la optimización, tal como lo muestra (3.11)

$$\begin{aligned} lb &\in [\text{rango mínimo de } x] \\ ub &\in [\text{rango máximo de } x] \end{aligned} \quad (3.11)$$

Función a minimizar o función de costo

Debido a que el modelo explicado en la sección 2.2 tiene el enfoque para que su salida sea el indicador de consumo específico, la función de costo por tanto consistirá en la minimización del índice de consumo de energía, ecuación (la del modelo).

Restricciones

Las restricciones son límites en los que se parametriza las 5 entradas del modelo, indicada con los parámetros lb y ub en (3.11)

Método

El método a utilizar para resolver el problema de optimización es el de programación no lineal implementado en MATLAB. Para este tipo de problema la herramienta utilizada es *fmincon* con los algoritmos Interior point, SQP y Active Set explicados en la sección 2.5.2. La Tabla 3.4 muestra una comparación con la optimización utilizando la herramienta *optimtool*.

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

Tabla 3.4 Rendimiento de optimización utilizando diferentes algoritmos

| Min. Encontrado | Número de Iteraciones | | |
|-----------------|-----------------------|-----|------------|
| | Interior point | SQP | Active Set |
| 28.2 | 32 | 11 | 5 |
| 27.26 | 28 | 11 | 5 |
| 26.71 | 24 | 21 | 21 |
| 25.85 | 33 | 17 | 11 |
| 24.53 | 32 | 16 | 16 |
| 24.329 | 28 | 13 | 12 |
| 23.61 | 41 | 16 | 15 |
| 22.61 | 29 | 14 | 13 |
| 21.99 | 37 | 33 | 35 |
| 20.34 | 38 | 25 | 34 |
| 19.94 | 34 | 34 | 21 |
| promedio | 32 | 19 | 17 |

La Tabla 3.4 muestra que para este problema de optimización tomando en cuenta el número de iteraciones los mejores son los algoritmos *Active set* y *SQP*, siendo el de mejor promedio de iteraciones el *Active Set*.

La Figura 3.24 muestra una pantalla de resultados de la herramienta *optimtool*. Donde *Current Function Value* es el valor de la función en cada iteración, notamos que en la iteración número 17 ya converge hacia un mínimo de la función, o sea, en este caso el consumo específico.

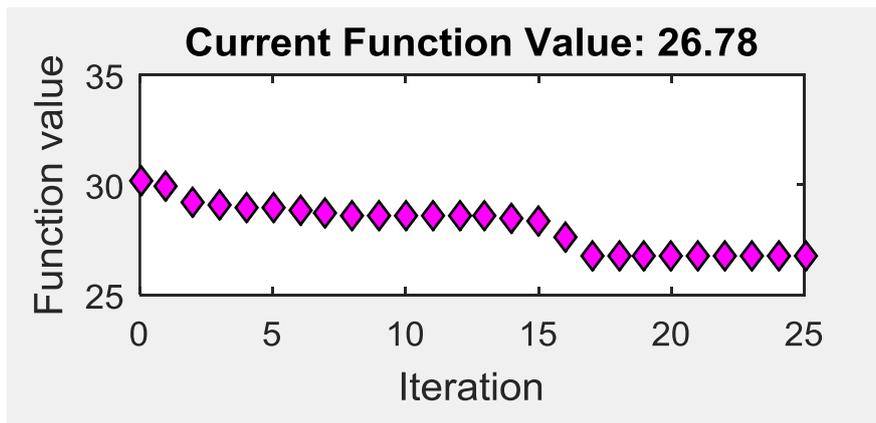


Figura 3.24 Ejemplo de resultado con *optimtool*

Sistema optimizador

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

La Figura 3.24 muestra la interfaz gráfica del optimizador. Para la explicación se divide en 3 recuadros.

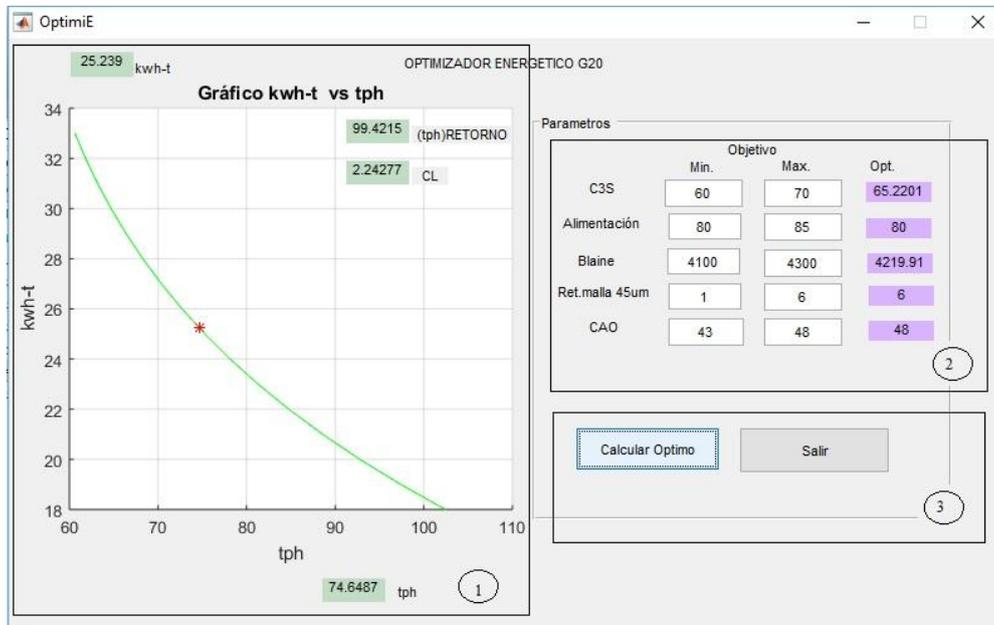


Figura 3.25 Interfaz del optimizador

En la Figura 3.25 en el recuadro 1 se puede apreciar la gráfica de la relación entre el consumo específico y la producción cuya ecuación es (3.6). Donde el eje de las abscisas representa la producción y las ordenadas el consumo específico. La curva verde grafica dicha ecuación. Cada punto encontrado de consumo específico es representado en esa gráfica con un asterisco rojo.

El recuadro 2 de la Figura 3.25 muestra los límites mínimos y máximos parametrizables, que permiten disponer de las restricciones tal como se mostró en la sección 3.5. En la Figura 3.25 en el recuadro 3 están los botones para calcular el óptimo y el botón de salir.

Después de colocar los límites en los que deseamos optimizar, al pulsar el botón de “Calcular Óptimo” se utiliza la función *fmincon* en MATLAB con el modelo principal. El programa calcula y devuelve los valores de entrada x que minimizan localmente el indicador de consumo específico (kwh/t). Teniendo el consumo específico en la ecuación (3.6) hallamos la producción, siendo este punto marcado con asterisco en rojo en la curva del recuadro 1, tal como se explicó anteriormente. Para este punto de

CAPÍTULO 3. METODOLOGÍA DE DISEÑO DEL SISTEMA OPTIMIZADOR

consumo específico los valores de x óptimos de entrada de la función de costo se colocan en la fila “Opt”. del recuadro 2, en los casilleros de color lila.

Con el valor de consumo específico calculamos el retorno aplicando la ecuación (3.7) y se presenta en la parte superior del recuadro 1. También se calcula el CL con la ecuación (3.4). Al establecer estas estimaciones permite utilizar el punto óptimo de consumo energético referenciado con las variables de retorno, CL y producción.

CAPÍTULO 4

4 VALIDACIÓN Y PRUEBAS

Este capítulo presenta pruebas de validación de los modelos de la sección 3.5.

4.1. PRUEBAS DEL COMPORTAMIENTO DE LOS MODELOS

La metodología de las pruebas está representada en la Figura 4.1 y los resultados se presentan con gráficas de las respuestas de los modelos comparadas con el valor del consumo específico calculado, con el mismo método explicado en la sección 3.5. Los datos utilizados como lo indica la Figura 4.1 son datos posteriores al período de modelación.

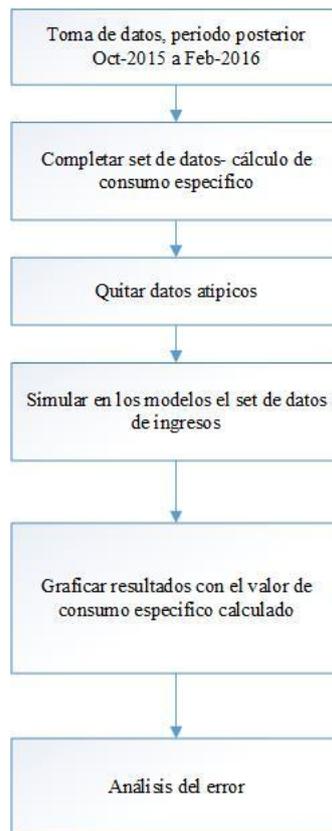


Figura 4.1 Metodología para la validación de los 3 modelos

CAPÍTULO 4. VALIDACIÓN Y PRUEBAS

La Figura 4.2 muestra el resultado de la validación del modelo desarrollado con redes neuronales con respecto a conjunto de datos real del consumo específico, en esta gráfica se verifica el error de predicción de este modelo.

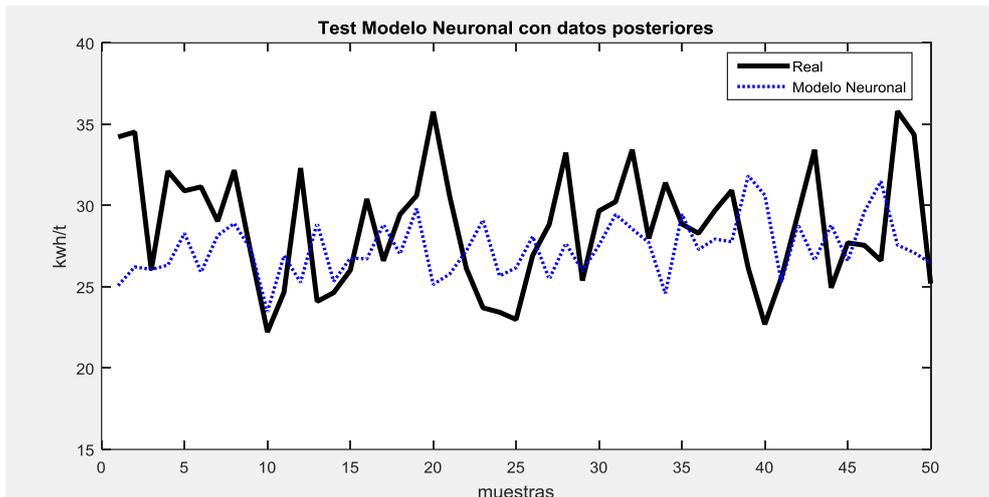


Figura 4.2 Respuesta del modelo neuronal con datos posteriores

La Figura 4.3 muestra el comportamiento de la estimación del modelo multivariable con respecto a consumo específico real, vemos que el modelo se equivoca y existe errores de predicción. En la Figura 4.3 están representados las 50 primeras muestras del conjunto de datos posteriores.

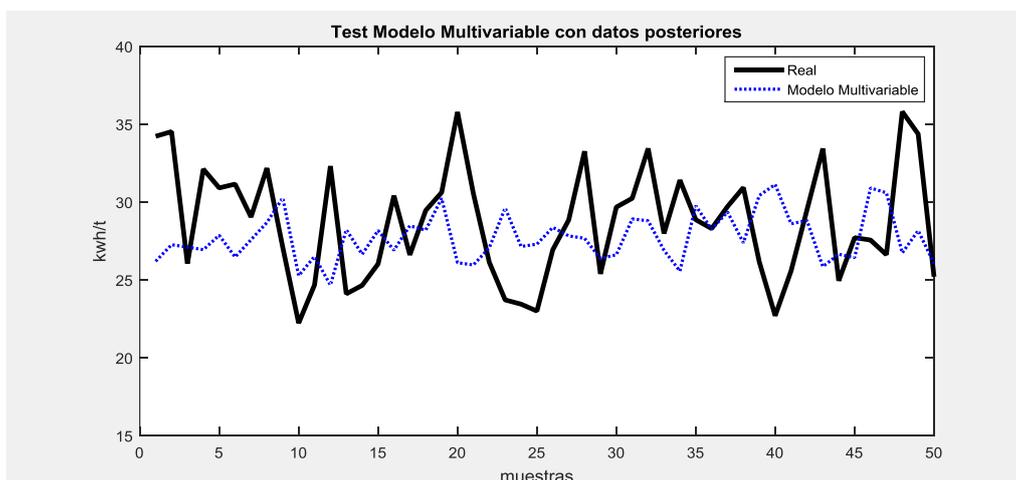


Figura 4.3 Respuesta del modelo multivariable con datos posteriores

CAPÍTULO 4. VALIDACIÓN Y PRUEBAS

La Figura 4.3 muestra el comportamiento del modelo neurodifuso, en esta gráfica de respuesta del modelo también hay error de predicción con respecto a los valores de consumo específico real.

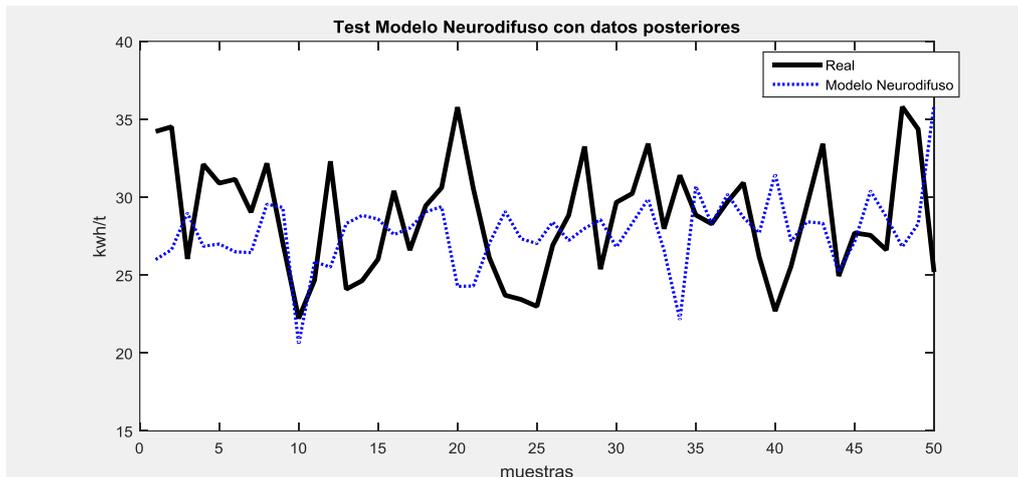


Figura 4.4 Respuesta del modelo neurodifuso con datos posteriores

La heurística del sistema de molienda provoca que los modelos encontrados presenten error en la predicción, por lo que es importante analizar la distribución del error y sus descriptivos estadísticos para elegir el modelo con mejor desempeño.

La Figura 4.5 muestra la distribución de los errores de los 3 modelos, vemos en la gráfica que en los modelos multivariable y neuronal su pico máximo está en el orden de 40, mientras que para el neurodifuso está en 60. La Figura 4.6 muestra la probabilidad normal de los errores de estimación con datos posteriores de los 3 modelos, vemos que la mejor probabilidad normal es de los modelos multivariable y de redes neuronales, siendo el neurodifuso con el de peor probabilidad en 0.98 y 0.02 con puntos de error de máximos de 25 y -20

CAPÍTULO 4. VALIDACIÓN Y PRUEBAS

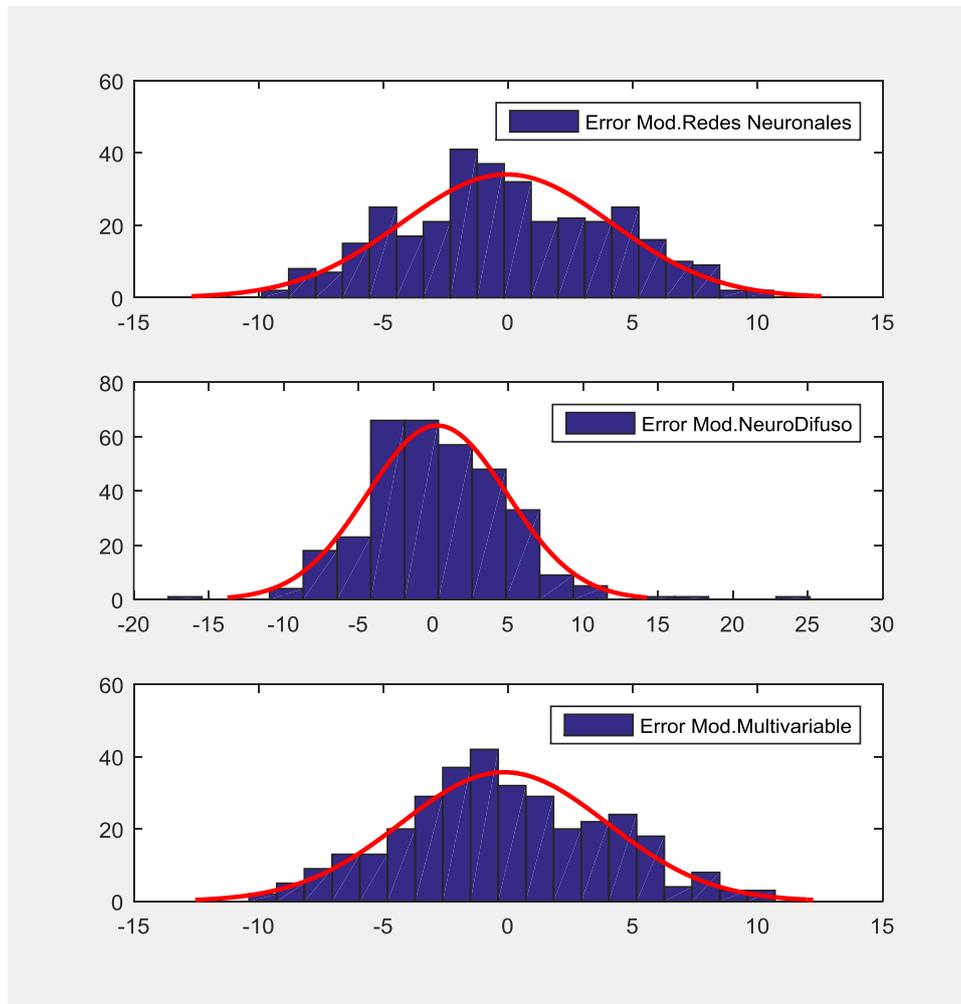


Figura 4.5 Gráfica de la distribución del error de los 3 modelos

CAPÍTULO 4. VALIDACIÓN Y PRUEBAS

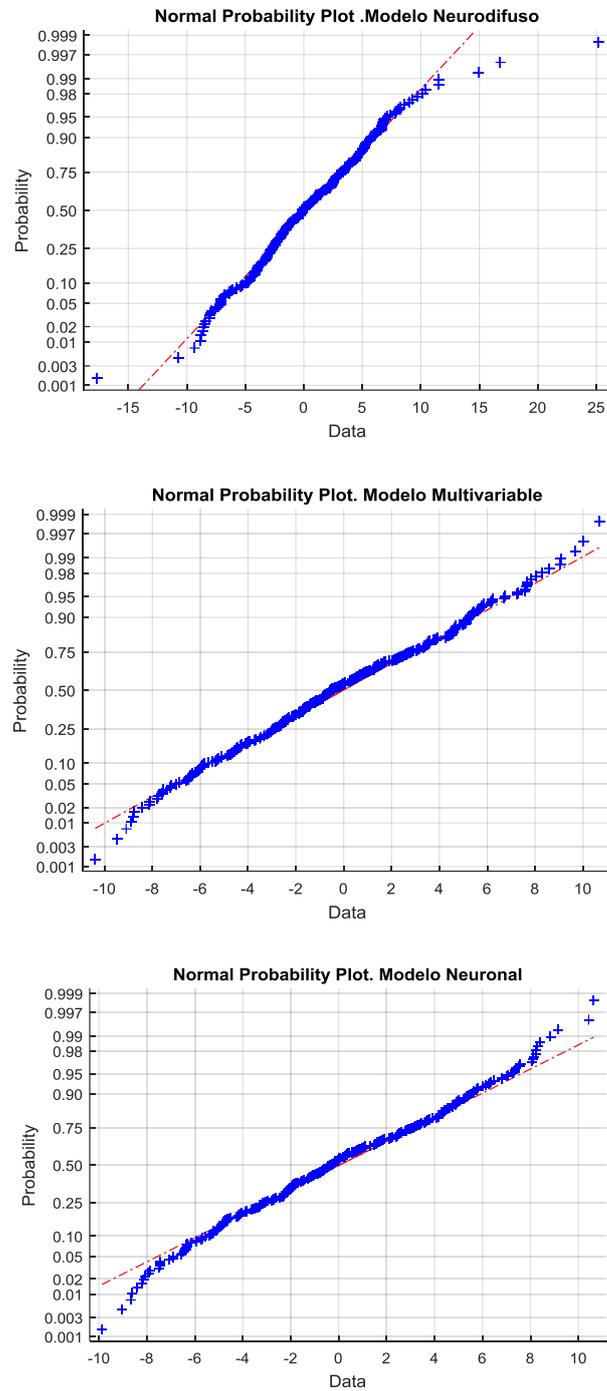


Figura 4.6 Grafica de la probabilidad normal de error de los 3 modelos

CAPÍTULO 4. VALIDACIÓN Y PRUEBAS

Tabla 4.1 Descriptivos del error con datos posteriores

| | Modelo Neuronal | Modelo Multivariable | Modelo Neurodifuso |
|----------|-----------------|----------------------|--------------------|
| Promedio | -0.07 | -0.16 | 0.26 |
| Máximo | 10.70 | 10.63 | 25.15 |
| Mínimo | -10.38 | -9.87 | -17.71 |
| Rango | 21.08 | 20.50 | 42.85 |

Las Figuras 4.5 y 4.6 muestran que los modelos de redes neuronales y multivariable presentan mejor distribución del error como se había mencionado.

Comparación de resultados de los modelos

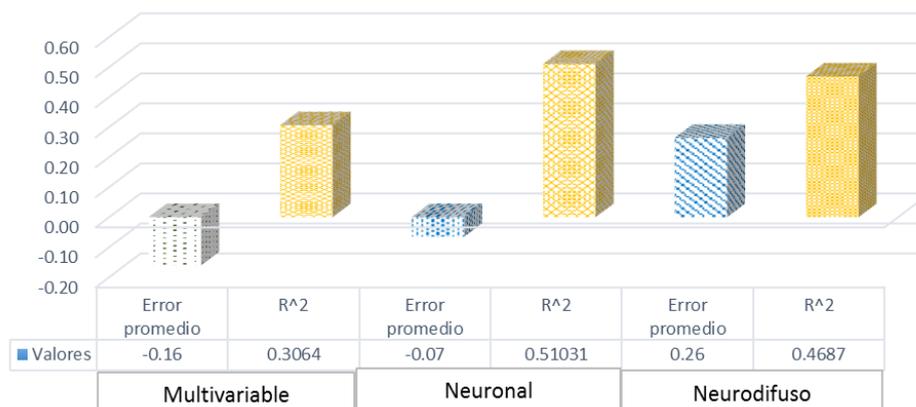


Figura 4.7 Comparación de resultados de los modelos

La Tabla 4.1 muestra los resultados de los descriptivos del error de los 3 modelos con datos posteriores, La Figura 4.7 muestra la comparación con el error promedio y el coeficiente de determinación R^2 , los mejores resultados se obtienen con los modelos estadístico multivariable y neuronal, ya que tiene menor error promedio, siendo el modelo neuronal con el valor de -0.07 el elegido para el sistema de optimización.

4.2. VERIFICACIÓN Y PRUEBAS DEL COMPORTAMIENTO DEL OPTIMIZADOR

Esta sección muestra los resultados de las pruebas realizadas del optimizador con el modelo de redes neuronales. Las pruebas se realizaron con dos conjuntos de datos: el de la modelización y el de la sección 4.1. La Figura 4.8 muestra la metodología utilizada

CAPÍTULO 4. VALIDACIÓN Y PRUEBAS

para estas pruebas. La Tabla 4.2 muestra las pruebas del optimizador realizadas con los datos de modelización, vemos los valores que encontró el optimizador, seguido de los valores cercanos del histórico hallados en dicho conjunto.

Tabla 4.2 Pruebas con datos de modelización

| C3S | Blaine | Ret45 | CAO | Alimenta | kwht | Prueba |
|-------|--------|-------|-------|----------|-------|-------------------|
| 65.22 | 4219 | 6 | 48.00 | 80 | 25.24 | Optimizador |
| 64.16 | 4117 | 4 | 46.50 | 78 | 27.38 | Datos Encontrados |
| 63 | 4300 | 6 | 50.00 | 75 | 22.36 | Optimizador |
| 61 | 4202 | 5.3 | 47.80 | 72.4 | 22.79 | Datos Encontrados |
| 60 | 4293 | 4.7 | 48.00 | 74 | 23.34 | Datos Encontrados |
| 69 | 4300 | 2.32 | 47.00 | 65 | 22.00 | Optimizador |
| 68 | 4268.2 | 2.8 | 49.00 | 65 | 20.66 | Datos Encontrados |
| 63 | 4662 | 2 | 47.00 | 69 | 20.00 | Optimizador |
| 61 | 4456 | 4.7 | 45.80 | 71.1 | 22.17 | Datos Encontrados |
| 70 | 4157 | 3 | 43.00 | 75 | 27.82 | Optimizador |
| 71 | 4209 | 4.6 | 45.00 | 73.2 | 29.46 | Datos Encontrados |

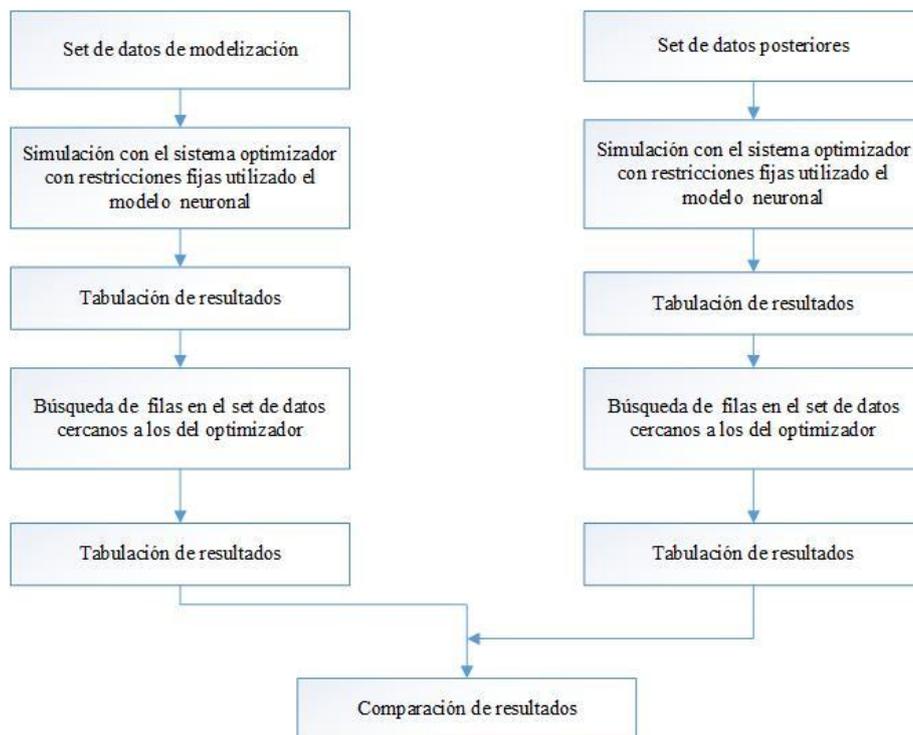


Figura 4.8 Metodología de verificación del sistema optimizador

CAPÍTULO 4. VALIDACIÓN Y PRUEBAS

Los resultados para el conjunto de datos posteriores se muestran en la Tabla 4.3 con la misma forma presentada en la Tabla 4.2.

Tabla 4.3 Pruebas con datos posteriores a los de modelización

| C3S | Blaine | Ret45 | CAO | Alimenta | kwht | Prueba |
|-------|------------------------|-------|------|----------|--------|-------------------|
| 65.22 | 4219.91 | 6 | 48 | 80 | 25.239 | Optimizador |
| 66.9 | 4256 | 6.5 | 46.4 | 79.2 | 27.42 | Datos Encontrados |
| 64 | 4000 | 1.92 | 43 | 75 | 29.88 | Optimizador |
| | valores no encontrados | | | | | No encontrado |
| 70 | 4400 | 3.65 | 50 | 85 | 21.1 | Optimizador |
| | valores no encontrados | | | | | No encontrado |
| 63.4 | 4400 | 4 | 46 | 70 | 23.9 | Optimizador |
| 61.7 | 4355 | 3.4 | 45.1 | 72.1 | 26.01 | Datos Encontrados |

4.3. ANÁLISIS DE RESULTADOS

Al verificar los resultados con el conjunto de datos de modelización en la Tabla 4.2 el optimizador cumple con encontrar valores cercanos a los hallados en este conjunto de datos, mientras que, los resultados expuestos en la Tabla 4.3 con el conjunto de datos posteriores establece que los valores encontrados por el optimizador son cercanos en menos casos, esto demuestra que la operación del sistema de molienda para el rango de tiempo posterior cambió la operación y no necesariamente se trabajó con bajo consumo específico. Para llevar a puntos de operación con menor consumo específico es necesario primero instaurar un régimen de estabilidad, en la que la variable de retorno se fije en un valor estable. Los dos conjuntos de datos no necesariamente cumplieron en sus registros con esta premisa. Luego para el tiempo considerado para la validación (conjunto de datos posterior), la heurística del sistema de molienda introduce transformaciones al modelo. Lo que significaría que sería necesario hallar otro modelo para el otro conjunto de datos, o modelizar de una forma dinámica encontrando modelos de redes neuronales paralelamente al funcionamiento del proceso.

CAPÍTULO 5

5 CONCLUSIONES Y RECOMENDACIONES

5.1. CONCLUSIONES Y COMENTARIOS

La modelación estática permite disponer de modelos de soporte a la operación. Sin embargo, los datos con los que se contaron para este trabajo, requerían preprocesamiento que ocasionó pérdida de dinámicas del proceso, provocando errores de estimación de los modelos.

El trabajar en modelos orientados a indicadores como la energía específica, ayuda a que el proceso de molienda sea más eficiente.

La herramienta de optimización desarrollada en este trabajo permite hallar puntos de operación de estado estable, que podrían formar parte de una arquitectura de control jerárquica en la que se consideren esos puntos como consignas de controladores distribuidos.

Es recomendable filtrar las variables de corriente del motor G20 y del motor del G31, así como también el flujo del retorno que permitirían mejorar en la variabilidad de la operación del sistema de molienda.

5.2. TRABAJO FUTURO

Desarrollar modelos dinámicos que estimen variables de calidad del clinker y del cemento. Estas predicciones trabajarían como analizadores virtuales en línea para enlazarlos con optimizadores en sistema supervisorios de control de indicadores de eficiencia como consumo específico e índice cemento – puzolana.

BIBLIOGRAFÍA

- Astolfi, A. (2010). Optimization An introduction. *The Journal of Analytical Psychology*, 55(5), 617–635. http://doi.org/10.1111/j.1468-5922.2010.01872_2.x
- Bahena, J. L. R., Genç, O., & Navarro, J. (2006). Efecto de la carga circulante de molienda de cementos en los parámetros del modelo matemático. Memoria Del XVI Congreso Internacional de Metalurgia Extractiva, (Abril), 278–287
- Bethea, R. M., Duran, B. S., & Boullion, T. L. (1985). *Statistical Methods for Engineers and Scientists*. (I. Marcel Dekker, Ed.). New York, NY.
- Boyd, S., & Vandenberghe, L. (2004). *Convex Optimization. Optimization Methods and Software* (Vol. 25). <http://doi.org/10.1017/CBO9780511804441>
- Castillo, E., Conejo, A. J., Pedregal, Pablo, R., García, N., & Alguacil. (2002). *Formulación y Resolución de Modelos de Programación Matemática en Ingeniería y Ciencia*.
- FLSmidt. (2010). *Comminution Manual*.
- Geoffrey Vining, & Kowalski, s. (2011). *Statistical Methods for Engineers* (third edition). Boston, MA USA.
- Gómez, S., Yanes, M., Rodríguez, G., Quiñones, F., & Torres, M. (2013). Determining cement ball mill dosage by artificial intelligence tools aimed at reducing energy consumption and environmental impact. *Ing. Investig.*, 33(3), 49–54. I. Viñuela, P.Galván, M. I. (2004). *Redes de Neuronas Artificiales: Un Enfoque Práctico*. (P. Hall, Ed.). Madrid.
- Ibrahim, W. R. A., & Morcos, M. M. (2002). Artificial Intelligence and Advanced Mathematical Tools for Power Quality Applications : A Survey, 17(2), 668–673.
- Jankovic, A., Valery, W., & Davis, E. (2004). Cement grinding optimisation. *Minerals Engineering*, 17(11-12), 1075–1081. <http://doi.org/10.1016/j.mineng.2004.06.031>
- Jyh-Shing Roger Jang. (1993). ANFIS: Adaptive-Network-Based Fuzzy Inference System. *IEEE Transactions on Systems, Man, and Cybernetics*, 23, 665–685.
- Kutner, M. H., Nachtsheim, C. J., Neter, J., & Li, W. (2004). *Applied Linear Statistical Models* (Fifth Edit).
- Zhang, L., & Luh, P. B. (2005). Neural Network-Based Market Clearing Price Prediction and Confidence Interval Estimation With an Improved Extended Kalman

Power Systems, IEEE Transactions on, 20(1), 59-66

Lind, Douglas A.; Marchal, William G.; Wathen, S. A. (2008). *Estadística aplicada a los Negocios y la economía*. (M. G. Hill, Ed.) (13th ed.). México DF.

López Pineda, G. (2013). *Análisis de Regresión para la Estimación del Secuestro de Carbono Orgánico en Suelos*.

Madlool, N. A., Saidur, R., Hossain, M. S., & Rahim, N. A. (2011). A critical review on energy use and savings in the cement industries. *Renewable and Sustainable Energy Reviews*, 15(4), 2042–2060. <http://doi.org/http://dx.doi.org/10.1016/j.rser.2011.01.005>

Marc Piccinin. (2016). Molino de bolas. recuperado de www.thecementgrindingoffice.com

Mathworks, C. (2015). Fuzzy Logic Toolbox™ User's Guide R 2015 b.

Mejeoumov, G. G. (2007). Improved cement quality and grinding efficiency by means of closed mill circuit modeling. Doctoral dissertation, Texas A&M University. Recuperado de <http://hdl.handle.net/1969.1/ETD-TAMU-2478>

Minchala, L. I., Sanchez, C., Yungaicela, N. M., Mora, A., & Mata, J. P. (2016, Feb). A comparative study of blackbox models for cement fineness prediction using scada measurements of a closed circuit grinding. *IEEE Latin America Transactions*, 14 (2), 673-680. doi: 10.1109/TLA.2016.7437209

Muralidharan, G., Chidambaram, M., Recke, B., & Jorgensen, J. B. (2013). Soft Constrained Based MPC for Robust Control of a Cement Grinding Circuit. In *Dynamics and Control of Process Systems* (Vol. 10, pp. 475–480).

Neter, J., M. H. Kutner, C. J. Nachtsheim, W. W. (1996). *Applied Linear Statistical Models*. (I. McGraw-Hill Companies, Ed.).

Nguyen, H. T., Prasad, N. R., Walker, C. L., & Walker, E. A. (2003). *A First Course in FUZZY and NEURAL CONTROL*.

Nocedal, J., Wright, S. J., Wright, S. J., & Robinson, S. M. (2006). *Numerical Optimization*. (Springer, Ed.) (Second Ed.).

Sahasrabudhe, R., Sistu, P., Sardar, G., & Gopinath, R. (2006). Control and optimization in cement plants. *IEEE Control Systems Magazine*, 26(6), 56–63. <http://doi.org/10.1109/MCS.2006.252832>

Sánchez Ayora, C. E., & Yungaicela Naula, N. M. (2015). *Estimación de modelos estáticos para variables de calidad en el circuito de molienda de UCEM, planta industrial Guapán*. Universidad de Cuenca. recuperado de <http://dspace.ucuenca.edu.ec/handle/123456789/23012>

Seber, G. A. ., & Wild, C. J. (1989). *Nonlinear Regression*. (John Wiley and Sons, Ed.). New York, NY.

Seber, G. A. F. (1989). *Linear Regression Analysis*. *Wiley Series in Probability and Mathematical Statistics*. (I. John Wiley and Sons, Ed.).

Subbaraj, P., & Anand, P. S. G. (2011). Optimal design of a fuzzy logic controller for control of a cement mill process by a genetic algorithm. *Instrumentation Science & Technology*, 39(3), 288–311. <http://doi.org/10.1080/10739149.2010.545850>

Tokyay, M. (1999). Effect of chemical composition of clinker on grinding energy requirement. *Cement and Concrete Research*, 29(4), 531–535. [http://doi.org/10.1016/S0008-8846\(98\)00219-1](http://doi.org/10.1016/S0008-8846(98)00219-1)

Touil, D., Belaadi, S., & Frances, C. (2006). Energy efficiency of cement finish grinding in a dry batch ball mill. *Cement and Concrete Research*, 36(3), 416–421. <http://doi.org/10.1016/j.cemconres.2005.12.005>

TR Chandrupatla, AD Belegundu. Prentice-Hall, (1991). 833*, 1991. *Optimization concepts and applications in engineering*. AD Belegundu, TR Chandrupatla

Van Breusegem, V., Chen, L., Bastin, G., Wertz, V., Werbrouck, V., & De Pierpont, C. (1996). An industrial application of multivariable linear quadratic control to a cement mill circuit. *IEEE Transactions on Industry Applications*, 32(3), 670–677. <http://doi.org/10.1109/28.502180>

Vera Lizcano, B. E. (2015). *Evaluación de errores de datos sísmológicos y sus efectos sobre los parámetros y modelos derivados de éstos para una región determinada cubierta por la red del Observatorio Sísmológico del SurOccidente - OSSO*. *PhD Proposal*. Universidad del Valle.