

Universidad Autónoma de Baja California

Instituto de Ingeniería

Algoritmo de Control Adaptativo basado en modelos
de aprendizaje estadístico para un Sistema de Barrido
Óptico.

Tesis para obtener el grado:
Maestro en ciencias

Presenta:
Moises Jesús Castro Toscano

Director:
Dr. Moises Rivas López

Co-Director:
Dr. Félix F. González Navarro

Dedicatorias

Con todo mi cariño y mi amor a las personas que hicieron todo en la vida para que pudiera lograr mis sueños, mis metas y darme la mano cuando sentía que el camino no tenía fin, a ustedes por siempre mi agradecimiento de todo corazón.

Mamá y Hermanos

A tu paciencia y comprensión, que preferiste sacrificar tu tiempo para que yo pudiera cumplir con el mío. Por tu sacrificio me inspiraste a ser mejor para ti, ahora puedo decir que esta tesis lleva mucho de ti, gracias por estar siempre a mi lado.

Marbella Pahua

Gracias a esas personas importantes en este camino de estudio, que siempre estuvieron listas para brindarme toda su ayuda, por auxiliar sin esperar nada a cambio, brindarme su amistad y compañerismo. Con agradecimiento les dedico a ustedes esta tesis:

Jesús Caro

Jesús Ernesto Valdez

Livier Rentería

Luis Roberto Ramírez

Marina Fernández

A ustedes que en este andar por la vida, influyeron con sus lecciones y conocimientos en formarme como una persona preparada para los retos del estudio, por apoyarme, guiarme y aconsejarme para concluir con esta investigación, les dedico cada una de estas páginas de mi tesis.

Dr. Moises Rivas López

Dr. Félix F. González Navarro

Reconocimientos

Al Consejo Nacional de Ciencia y Tecnología (CONACYT), por brindar el apoyo tanto económico como material para financiar la investigación y el trabajo, y al constante apoyo con becas para poder continuar con los estudios de posgrados en México y en el extranjero.

A la Universidad Autónoma de Baja California (UABC), por darme la oportunidad de estudiar mi posgrado, y poder obtener mí grado en Maestro en Ciencias.

Al Instituto de Ingeniería de la UABC, por brindar las aulas, los espacios y a los catedráticos en la formación académica de los estudiantes de posgrados.

A mi director de tesis, Dr. Moises Rivas López, por generar este proyecto de investigación y permitirme participar en él, compartiendo su conocimiento respecto al campo de estudio y su experiencia.

A mi codirector de tesis, Dr. Félix F. González Navarro, por trabajar en cooperación con el Dr. Moises Rivas López en este proyecto de investigación, por su tiempo, dedicación y consejos al proyecto.

Resumen

Este trabajo de investigación se centra en el estudio de la viabilidad de la aplicación práctica de los modelos de aprendizaje estadísticos en el campo de la ingeniería, particularmente en áreas de opto electrónica y mediciones automáticas, como lo son las tareas de monitoreo de integridad estructural conocidas por sus siglas en ingles SHM (Structural Health Monitoring). Tanto la formulación teórica de estas herramientas como los resultados conseguidos en otros campos han llevado a considerar estos modelos como una opción apropiada para resolver algunos problemas de la Ingeniería de automatización. En concreto, esta tesis dirige su atención a tres modelos inteligentes particulares, Mínimos Cuadrados Parciales (PLS), Redes Neuronales Artificiales (RNA) y Máquinas de Vectores de Soportes (SVM), en la implementación de tareas de monitoreo de integridad estructural.

El estudio experimental se llevó a cabo en un prototipo para tareas de SHM, desarrollado en las instalaciones del Instituto de Ingeniería de la Universidad Autónoma de Baja California. En este prototipo las mediciones se llevan a cabo respecto a un espejo cilíndrico con una superficie de reflexión a 45° el cual gira sobre su mismo eje, teniendo así un reflejo del haz de luz emitida por una fuente de luz a un fotodetector, generando una señal eléctrica y posteriormente la detección del centro de la señal.

De esta manera dos líneas de trabajo fueron realizadas, la primera línea de trabajo se centra en generar una etapa de control adaptativo al prototipo, puesto que este carece de alguno en su funcionamiento, dejando al sistema con posibles errores en sus mediciones e incluso en su funcionamiento propio. En una segunda etapa se basa en realizar un estudio de comparación entre los modelos para poder seleccionar el de mejor rendimiento, esto para poder generar una predicción en tiempo real en el sistema de barrido óptico respecto a las variables de entrada.

Los resultados obtenidos de esta experimentación y de su implementación en el sistema de control, reflejan una mejora del funcionamiento del prototipo respecto a lo que antes se tenía, un prototipo de barrido óptico sin un control adaptativo basado en un modelo de aprendizaje estadístico.

Índice General

1. Introducción	1
1.1 Planteamiento del problema	3
1.2 Objetivos de la investigación	4
1.2.1 Objetivo general	4
1.2.2 Objetivos específicos.....	4
1.3 Justificación del estudio	5
2. Marco teórico	7
2.1 Monitoreo de la Integridad Estructural	7
2.1.1 Métodos de Detección de Fallas en Estructuras	7
2.2 Sistema de Barrido Óptico	8
2.2.1 Funcionamiento del Sistema de Barrido Óptico.....	9
2.3 Control Adaptativo.....	11
2.3.1 Conceptos y Teoría del Control.....	12
2.3.2 Métodos de Control y Acciones Básicas	16
2.4 Modelos de Aprendizaje Estadístico	17
2.4.1 Conceptos Básicos Estadísticos.....	18
2.4.2 Mínimos Cuadrados Parciales	24
2.4.3 Redes Neuronales	27
2.4.4 Maquinas de Vector de Soporte	32
3. Materiales y Métodos.....	36
3.1 Materiales	36
3.2 Métodos	36
4. Resultados y Discusión	42
4.1 Resultados Experimentales	42
4.2 Discusión de Resultados.....	48
5. Conclusiones.....	49
5.1 Trabajos Futuros.....	50
Referencias	51
Anexos	53

Índice de Figuras

1.1 Detección del centro de la señal Gaussiana	3
2.1 Esquema del Sistema de Barrido Óptico	9
2.2 Funcionamiento del Sistema de Barrido Óptico	10
2.3 Sincronizado del sensor S, pulso indica inicio y pulso final	11
2.4 Bloque Funcional “Bloque”	13
2.5 Diagrama de Bloques, Punto Suma o Diferencia	13
2.6 Diagrama de Bloques, Punto de Ramificación	13
2.7 Teorema de Superposición	14
2.8 Diagrama de Bloque, Lazo Abierto	15
2.9 Sistema de Control Lazo Cerrado Realimentado.....	15
2.10 Diagrama de Bloques, Control Adaptativo	16
2.11 Estructura de una Muestra	19
2.12 Descripción grafica de un banco de datos.....	19
2.13 Distribución Normal (<i>curva normal</i>)	20
2.14 Descripción gráfica de Validación Cruzada	21
2.15 Modelo PLS: T (X score), U (Y score), Q (Y loading), P (X loading)	25
2.16 Modelo de una neurona sencilla	28
2.17 Función de transferencia	29
2.18 Arquitectura RNA, una capa oculta.	30
2.19 Proceso matricial RNA, una capa oculta	30
2.20 RNA con tres capas ocultas.	31
2.21 Proceso matricial RNA, tres capas ocultas	31
2.22 Espacio característico de dos dimensiones	32
2.23 Arquitectura SVM- Regresión	35
3.1 Comportamiento de los datos de prueba y datos de entrenamiento.	37
3.2 Descripción Grafica de la Experimentación	38
3.3 Relación Voltaje-Frecuencia motor	39
3.4 Control Integral Frecuencia- Frecuencia	40
3.5 Implementación de Control de Lazo Abierto a Control de Lazo Cerrado.	40
4.1 Visualización de Valores de Predicción y Valores Reales	44

4.2 SVM-Kernel Base Radial Mejorado	46
4.3 Sistema de Control Retroalimentado con Modelo Matemático	46
4.4 Señal Gaussiana Resultados.....	47

Lista de tablas

3.1 Relación lineal Voltaje del motor y frecuencia del motor	39
4.1 Errores en Etapa de Prueba en PLS, RNA, MSE.....	43
4.2 Parámetros Óptimos de la RNA y SVM.....	45

Acrónimos

BFG	<i>Quasi Newton Backpropagation</i>
I	<i>Control Integral</i>
LM	<i>Levenberg Marquardt Backpropagation</i>
MSE	<i>Error Cuadrático Medio</i>
P	<i>Control Proporcional</i>
PCA	<i>Análisis de Componentes Principales</i>
PI	<i>Control Proporcional Integral</i>
PLS	<i>Mínimos Cuadrados Parciales</i>
RMSE	<i>Raíz Cuadrada del Error Cuadrático Medio</i>
RNA	<i>Redes Neuronales Artificiales</i>
RP	<i>RPROP Backpropagation</i>
SVM	<i>Maquinas de Vectores de Soporte</i>
SHM	<i>Monitoreo de Integridad Estructural</i>
TRN	<i>Base de Datos de Entrenamiento</i>
TST	<i>Base de Datos de Prueba</i>

Capítulo 1.

Introducción

Con el incremento de nuevas infraestructuras civiles en todo el mundo y la creación de nuevos equipos de sensado, el desarrollo de un sistema de identificación de daños que pueda extraer información cuantitativa y pueda proveer el desempeño de la estructura se ha convertido en un tema de investigación [27]. Las tareas de monitoreo de integridad estructural, conocidas por sus siglas en inglés SHM (Structural Health Monitoring), tienen importancia en diferentes áreas, como lo son la ingeniería civil, mecánica, minera y aeroespacial, entre otras [3], ya que permite seguir el comportamiento de un determinado sistema estructural detalladamente. El SHM consiste en la implementación de un sistema para detectar daños en el cual envuelve monitoreo, procesamiento de datos y su interpretación para evaluar la condición de una estructura, teniendo como uno de los objetivos el poder detectar diferentes daños en la estructura en su estado inicial que producen deformaciones y tomar la decisión del correspondiente mantenimiento, que de no ser detectadas, pueden provocar un fallo crítico en la estructura y provocando el colapso de la misma, teniendo a su vez pérdidas humanas y económicas [5].

Actualmente existen varios estudios que reportan los resultados de diferentes métodos y sistemas relacionados con las tareas de SHM; en las últimas décadas destacan los sistemas a base de fibras ópticas, redes inalámbricas, cámaras de video y recientemente, los sistemas de barrido óptico [4].

Los sistemas de barridos ópticos, son sistemas que trabajan con una unidad de desviación de haz de luz para hacer el barrido, basada en espejos poligonales giratorios, espejos planos o espejos prismáticos y un sensor de captación pudiendo ser un fotodiodo [24] que junto a componentes mecánicos, circuitos de control, algoritmos matemáticos y procesamiento de señales, definen tanto la resolución como la exactitud del sistema. Los sistemas de barridos ópticos se basan en la distribución espacial de la luz emitida por una fuente de luz no coherente, que al pasar por una apertura circular, produce una señal eléctrica ideal por el sensor de captación, generando una señal en forma Gaussiana.

Como se mencionó anteriormente existen factores que definen la resolución y la exactitud de un sistema de barrido óptico como puede ser circuitos de control. El control adaptativo es un tipo especial de control el cual consiste en adaptar los parámetros variables de un proceso a fin de mantener un funcionamiento adecuado de un sistema, este tiene como objetivo controlar las salidas de alguna forma prescrita mediante las entradas a través de los elementos del sistema, controlando las condiciones en que se mide y se controla una variable, por lo común la variable controlada es la salida de un sistema. De esta forma se pueden resolver errores de ganancias las cuales pueden cambiar, por dar un ejemplo, con los cambios ambientales; si un sistema cambia su comportamiento debido a cambios de los parámetros del proceso, entonces el control adaptivo ajusta las variables.

Los algoritmos matemáticos son otro factor que define la resolución de un sistema de barrido óptico, el aprendizaje estadístico puede ser empleado a través de algoritmos matemáticos, el aprendizaje estadístico trabaja a partir de un conjunto de información acerca de un proceso, construyendo un modelo que permita predecir nuevos fenómenos asociados a él [21]. También debe el modelo tener la capacidad de generalizar [19]. Entonces se hace necesario que el aprendizaje efectúe algún tipo de inducción a partir de la información disponible.

Para poder inducir al modelo se necesita un conjunto de medidas o ejemplos asociados al proceso que se desea modelar [16]. Estos ejemplos o muestras elevan la complejidad del problema a modelar si se toman en cuenta:

1. El número de variables, que está asociado al número de entradas de la función, puesto que los procesos a modelar por estos sistemas suelen ser altamente complejos.
2. Las muestras disponibles, éstas suelen ser escasas y tener cierta incertidumbre.

Existen diferentes modelos de aprendizaje estadístico que pueden implementarse en los sistemas de barrido óptico, teniendo como resultados algoritmos matemáticos que tengan la habilidad de adaptar sus variables de salidas como: velocidad del motor, voltajes de salidas y corrientes de alimentación, con respecto a las variables de entrada como pueden ser: la distancia a la que se encuentra el emisor de luz y el sistema de barrido, ángulos de posiciones del emisor, entradas de señales no deseadas, entre otras, generando así autocorrecciones en el sistema y controles adaptativos en la planta, permitiendo que los algoritmos mantengan un control estable al

momento de realizar las tareas SHM. Por tal motivo en esta investigación se propone la implementación y análisis de tres modelos de aprendizaje:

1. Mínimos Cuadrados Parciales (PLS).
2. Redes Neuronales Artificiales (RNA).
3. Máquina de Vectores de Soporte (SVM).

Esta tesis consta de los siguientes capítulos, en el capítulo #1 se presenta una descripción del problema, además se plantean el objetivo general y los objetivos específicos del trabajo al igual que las justificaciones del estudio. En el capítulo #2 se realiza una revisión teórica de los conceptos empleados en la investigación, estableciendo las bases matemáticas para resolver el problema propuesto. En el capítulo #3 se presenta la metodología seguida para la realización de la investigación. En el capítulo # 4 se muestran los resultados y en el capítulo #5 se presentan las conclusiones del trabajo.

1.1 Planteamiento del problema

Actualmente los sistemas de barrido óptico tienen diversas aplicaciones y cada aplicación requiere de una resolución y exactitud determinada para medir cambios mínimos que pueda tener el objeto de observación [20]. El laboratorio de optoelectrónica y mediciones automáticas del Instituto de Ingeniería de la Universidad Autónoma de Baja California ha desarrollado un método para tareas de SHM, generando una señal eléctrica en forma Gaussiana y por medio de circuitos eléctricos se da la detección del centro de la señal Gaussiana(figura 1.1).




Figura 1.1: Detección del centro de la señal Gaussiana [20].

En experimentaciones preliminares, se detectaron diferentes problemas con el prototipo. Se observó que el prototipo carecía de un sistema de control, por lo tanto al momento de realizar las pruebas, el motor que tiene como función el giro del espejo cilíndrico, trabajaba a frecuencias distintas a las que el operador solicitaba, con lo cual afectaba la lectura de la señal Gaussiana y

por lo tanto a su detección del centro. De igual manera se observó que el prototipo carecía de un agente inteligente que lo pudiese autocorregir al momento de emplear las lecturas, generando errores en las mediciones obtenidas al ser usado el prototipo.

Es importante poder solucionar estos detalles en el prototipo por la razón principal de que al analizar y diagnosticar el estado de una estructura se determinan las medidas necesarias para corregir el estado de la estructura, lo que permitirá su operación o programar su reparación o su retiro. Por ello es necesario contar con un sistema independiente de la estructura el cual pueda ser reconfigurado para monitorear y analizar las características particulares de cada estructura.

1.2 Objetivos de la investigación

1.2.1 Objetivo general

El objetivo general de esta investigación es generar un algoritmo de control adaptativo, que pueda aprender con el menor error posible la frecuencia de operación del motor de giro, a diferentes variables de entrada, por medio de modelos de aprendizaje estadísticos.

1.2.2 Objetivos específicos

1. Generar un algoritmo de control adaptativo que controle y asegure la frecuencia de operación del motor deseada por el operador.
2. Construir un banco de datos apropiado para el entrenamiento y aprendizaje de los modelos de aprendizaje estadístico.
3. Definir los parámetros óptimos de los modelos de aprendizaje estadísticos empleados para la base de datos construida.
4. Comparar el desempeño de predicción entre los modelos de aprendizaje estadístico, para su selección y su implementación en el prototipo.
5. Establecer el modelo matemático y sus parámetros óptimos del modelo de aprendizaje con mejor desempeño.

1.3 Justificación del estudio

Las tareas de monitoreo para medición de deformaciones de grandes estructuras requieren de la adquisición de información rápida, exacta, precisa y a bajo costo. Existen sistemas basados en cámaras de video para realizar estas tareas, pero estos se vuelven costosos e ineficientes por el retraso temporal en el procesamiento de la imagen, además agregando factores que dificultan la saturación de datos en condiciones adversas, como escasa iluminación, polvo, lluvias, ruido y sobre todo el gran recuso computacional que requiere el análisis de video[4].

Los sistemas de barrido óptico permiten obtener cientos y hasta miles de mediciones de uno o varios puntos, en cortos periodos de tiempo con altas resoluciones, dejando en claro las ventajas que tienen estos sistemas:

- Bajo Costo de implementación.
- Adquisición de información de manera rápida y exacta.
- Alta resolución del orden de milímetros.
- Posibilidad de examinar estructuras en áreas remotas.
- Escanear estructuras complejas.

Los sistemas de barrido óptico pueden utilizar fuentes emisoras de luz coherente, como el láser o fuentes de luz no coherente, facilitando por mucho la utilización de estos sistemas en tareas de SHM [24] [5]. Aun así estos sistemas de barrido óptico llegan a presentar fallas durante la obtención de mediciones, ya que carecen de retroalimentación en el sistema. Algunas de estas fallas pueden ser: el reconocimiento de parámetros a nuevas variables de lectura, nuevos parámetros de mediciones a diferentes frecuencias del barrido.

Por lo tanto el trabajo de tesis propone no solo la implementación de un sistema retroalimentado, sino un sistema que a su vez se encuentre controlado por medio de algoritmos de aprendizaje estadístico, por su fácil implementación tanto práctica como en la cuestión económica, de igual manera por la alta capacidad de generalizar problemas, rápidas respuestas a variables oscilantes y la capacidad de desarrollar aprendizaje autodidáctico.

De tal manera la implementación del aprendizaje estadístico a partir de algoritmos matemáticos es factor primordial para determinar una mejor resolución del sistema de barrido óptico, dejando a

seleccionar una amplia variedad de modelos simples o complejos y avanzados de aprendizajes estadísticos que se pudiesen adaptar en estos tipos de sistemas. Implementando alguno de estos modelos obtendremos un sistema controlado y automatizado, que a su vez evitará trabajar con mediciones erróneas. Estos modelos de aprendizaje trabajarán a partir de información recolectada acerca del proceso empleado en las tareas de SHM, construyendo así un modelo que llegue a tener la capacidad de predecir fenómenos, generalizar procesos y predecir respuestas asociadas a las tareas de SHM, dejando en claro que un sistema con estas cualidades tendrá una notable ventaja con respecto a sistemas que solo se basan en métodos analógicos sin ningún tipo de procesamiento y aprendizaje de información. Lo anterior justifica la propuesta que se expone en la presente investigación.

2.1 Monitoreo de la integridad estructural

El monitoreo de la integridad estructural “Structural Health Monitoring” SHM, es una área de investigación de rápido crecimiento que está atrayendo el interés de los investigadores y de agencias de gobierno relacionados con el mantenimiento y seguridad de los diferentes tipos de estructuras tales como edificios, puentes y estructuras de barras articuladas, con el fin de permitir su operación o programar su reparación o retiro [5]. El monitoreo de la salud estructural consiste en el proceso de implementar una estrategia de identificación de daños que envuelva la observación de una estructura a lo largo del tiempo empleando mediciones espaciadas y el análisis de estas para determinar el estado actual de la estructura.

El termino daño puede ser definido como los cambios introducidos dentro del sistema que afectan negativamente su actual o futuro rendimiento y requiere una comparación entre dos estados diferentes del sistema, uno de los cuales representa el estado inicial y el estado actual, el cual debe ser evaluado como sano o dañado [27].

2.1.1 Métodos de detección de fallas en estructuras.

Durante los últimos años se han propuesto diversos métodos clásicos y dinámicos para evaluar el daño en estructuras. A continuación se describirán estos métodos.

Los *métodos clásicos* o también llamados técnicas no destructivas consisten en procedimientos visuales o experimentales, tales como:

1. Inspección visual. Este tipo de métodos incluyen algunas variantes de niveles de especialización que van desde una evaluación óptica a simple vista hasta un barrido electrónico para obtener información detallada de las fracturas. La evaluación óptica aunque es más simple y económica tiene sus limitaciones en materiales compuestos donde las fallas muchas veces ocurren en capas interiores.

2. Emisión ultrasónica. Este método consiste de dos cabezales hidrodinámicos acoplados en tándem que al pasar por la superficie del elemento envía ondas ultrasónicas por medio del chorro de agua en un lado, mientras que del otro lado se reciben las ondas acústicas transmitidas. El inconveniente de este método además del tamaño y del costo del equipo, es la necesidad de tener acceso a ambos lados de la superficie o incluso el tener que desmontar los elementos de la estructura.
3. Rayos X. Este método basa su principio de funcionalidad en la variación de absorción de rayos X a través de una superficie. Sin embargo, es de un alto costo y presenta la necesidad de tener acceso a ambos lados de la superficie con el fin de emitir y coleccionar los rayos X.

Los *métodos dinámicos* están basados en los cambios de vibración de la estructura, ya que la medición es suficientemente sensible para detectar daños, inclusive cuando los daños estén localizados en áreas internas de la estructura. La idea básica del método dinámico está basada en vibraciones debido a que una falla afecta a la respuesta vibratoria de la estructura afectando sus parámetros, tales como frecuencia natural, factores de amortiguamiento, entre otros. Sin embargo este tipo de métodos requieren de equipos especializados, sin mencionar de los altos costos en su manejo.

2.2 Sistema de Barrido Óptico

Actualmente los sistemas de monitoreo por medio de barridos ópticos tienen diversas aplicaciones y en cada una de ellas se requiere de una resolución y exactitud determinada para medir los cambios mínimos que puede presentar el objeto bajo observación [3]. Estas mediciones por lo regular se ven afectadas por diversos factores: ruido externo, velocidad del barrido, perturbaciones o fuentes externas, como la luz solar, que interfieren con la longitud de onda de la fuente emisora al igual que, los fenómenos de reflexión, difracción, absorción y refracción [4].

2.2.1 Funcionamiento del Sistema de Barrido Óptico

Los sistemas de barridos ópticos trabajan con una unidad de desviación de haz de luz para hacer el barrido, basada en espejos poligonales giratorios, espejos planos o espejos prismáticos y un sensor de captación pudiendo ser un fotodiodo [24] que junto a componentes mecánicos, circuitos de control, algoritmos matemáticos, procesamiento de señales, se definen la resolución y la exactitud del sistema. Los sistemas de barridos ópticos se basa en la distribución espacial de la luz emitida por una fuente de luz no coherente, que al pasar por una apertura circular, produce una señal eléctrica ideal por el sensor de captación, generando una señal en forma Gaussiana (figura 2.1).




Figura 2.1: Esquema del Sistema de Barrido Óptico.

El prototipo desarrollado en el laboratorio de opto electrónica y mediciones automáticas del Instituto de Ingeniería de la Universidad Autónoma de Baja California trabaja con el principio de operación que se basa en un espejo cilíndrico con una sola superficie de reflexión a 45° , el cual gira sobre su mismo eje a una velocidad determinada, así de esa manera reflejará el haz de luz emitida por una fuente de luz a un fotodetector, generando una señal eléctrica en forma Gaussiana y por medio de circuitos eléctricos se obtiene la detección del centro de la señal Gaussiana (figura 2.2).




Figura 2.2: Funcionamiento del Sistema de Barrido Óptico.

Tomando como referencia la figura 2.1 podemos apreciar el funcionamiento del sistema de barrido óptico, el cual se compone de emisores de luz, colocados a una distancia l del receptor, que se conforma de un espejo cilíndrico E , que gira con una velocidad ω .

El haz de luz emitido por la fuente i , llega con un ángulo de incidencia β , con respecto a la perpendicular del espejo, por lo que es reflejado con un mismo ángulo β de acuerdo a la ley de reflexión [5]. El haz de luz al pasar a través de un lente se concentrará para ser captada por un foto-detector, el cual genera una señal f en forma de una función Gaussiana que posteriormente será procesada.

Al inicio del giro del espejo, un sensor S es sincronizado con el origen, generando un pulso que indica el inicio de la medición, la cual termina cuando el foto-detector emite la señal de alto para finalizar la medición. Para aumentar la exactitud de la medición, el pulso de alto es generado cuando un circuito electrónico detecta el centro de la señal Gaussiana como se muestra en la figura 2.3.




Figura 2.3: Sincronizado del sensor S, pulso indica inicio y pulso final.

Donde α es el mensurado y representa el ángulo entre el origen y la posición de la fuente emisora de luz, t_α simboliza el tiempo transcurrido entre los pulsos de inicio y de alto de la medición, $T_{2\pi}$ es el tiempo que transcurre en un periodo y ω es la velocidad angular de barrido.

De este modo el ángulo α se puede obtener de la siguiente manera:

$$\alpha = \omega t_\alpha \quad (2.1)$$

O bien introduciendo una frecuencia de referencia f el ángulo se puede obtener mediante la siguiente expresión matemática:

$$\alpha = 2\pi \cdot N_\alpha / N_{2\pi} \quad (2.2)$$

Donde: N_α representa la cantidad de pulsos de la frecuencia f contenidos entre el pulso de inicio y el pulso de terminación de la medición y $N_{2\pi}$ representa la cantidad de pulsos de la frecuencia f contenidos en un periodo $T_{2\pi}$ [20].

2.3 Control Adaptativo

Constantemente en tareas de SHM como en los sistemas de barrido óptico se ha buscado generar una automatización en la toma de mediciones, donde los usuarios puedan obtener lecturas con mayor facilidad y de igual forma con el menor error posible. Por lo tanto se han estado empleando conceptos teóricos y prácticos del control. Las técnicas de control adaptativo surgen a partir de 1950 con el fin de dar solución a problemas de control en los que las características del sistema a controlar son variables, el término control adaptativo posee diversos significados pero, en términos generales, implica que un sistema mida las características dinámicas de una planta en

forma continua y automática, las compare con las características deseadas y utilice la diferencia entre ambas para variar los parámetros del sistema [10].

A continuación se darán conceptos básicos y teorías del control necesarios para el entendimiento del control adaptativo.

2.3.1 Conceptos y Teoría del Control

En la teoría del control existe el término de *variable controlada*, es la cantidad o condición que se mide y controla, por lo común la variable controlada es la salida del sistema [10]. Una vez empleado el control podemos definir como medir el valor de la variable controlada del sistema y aplicar una “variable manipulada” para la corrección a la desviación. La *variable manipulada* es la cantidad o condición que el controlador modifica para afectar el valor de la variable controlada [11].

Otro termino importante es el de *planta* siendo este el elemento físico que se desea controlar [10], la planta puede ser un motor, un horno, un sistema de navegación. Los cuales pueden ser afectados por *perturbaciones*, estas perturbaciones son señales que tiende a afectar la salida del sistema desviándola del valor deseado [10]. Las *señales de salida* son señales de la variable que se desea controlar, puede ser posición, velocidad, presión, temperatura, también se le llama variable controlada [10].

En sistemas controlados un término importante que ayuda a tener la certeza de que la variable controlada efectivamente está siendo controlada son las *señales de error*, estas señales son la diferencia entre la señal de referencia y la señal de salida real [10].

Para el entendimiento y su representación gráfica de los sistemas controlados se usan *diagrama de bloques*, un diagrama a bloques de un sistema, es una representación gráfica de las funciones que lleva acabo cada componente, así como también el flujo de las señales, estos diagramas muestran las relaciones existentes entre los diversos componentes, a diferencia de la representación matemática abstracta, un diagrama a bloques tiene la ventaja de identificar en forma más realista el flujo de las señales del sistema real [11].

Un bloque funcional o “bloque”, es un símbolo para representar la operación matemática que hace el sistema sobre la señal de entrada para producir una salida, estas funciones de transferencia por lo general se introducen en bloques correspondientes, que se conectan por medio de flechas para indicar la dirección del flujo de la señal (figura 2.4).




Figura 2.4 Bloque funcional, “Bloque”

Simbología

- Bloque o bloque funcional




Figura 2.4 Bloque funcional, “Bloque”

- Punto Suma o Diferencia, Es un círculo con una cruz, es el símbolo que indica una operación de suma, el signo (+) o (-) en cada punta de la flecha indica si la señal debe sumarse o restarse (figura 2.5).




Figura 2.5 Diagrama de bloques, Punto Suma o Diferencia.

- Punto de ramificación, es aquel punto a partir el cual, la señal de un bloque va de modo concurrente a otros bloques o punto suma (figura 2.6).




Figura 2.6 Diagrama de bloques, Punto de Ramificación

En la teoría del control existen diferentes tipos de *sistemas de control* que son conjuntos de componentes interconectados de modo que pueden ser comandados, dirigidos o regulados por si mismos o por otro sistema para lograr una condición deseada [11], el objetivo de un sistema de control es controlar las salida en alguna forma prescrita mediante las entradas a través de los elementos del sistema de control. A continuación se presentan algunos de los sistemas de control básicos:

1. Sistema lineal: se define como aquel cuyo comportamiento puede describirse con un conjunto de ecuaciones diferenciales lineales ordinarias de primer orden, se denomina lineal si se aplica el principio de superposición [11].

Principio o Teorema de superposición

Este principio establece que la respuesta producida por la aplicación simultanea de 2 funciones de excitación o entradas diferentes, es la suma de respuestas individuales (fórmula 2.3) [10] [11].

$$f(\alpha u_1 + \beta u_2) = \alpha f(u_1) + \beta f(u_2) \quad (2.3)$$

Este teorema puede comprenderse como la entrada de variables y son afectadas linealmente por el sistema (figura 2.7).




Figura 2.7, Teorema de Superposición, a y b son las entradas al sistema lineal.

2. Sistema de Control Lazo Abierto: es un sistema de control en el que aunque se actúa sobre algunas variables no se efectúa un auto-corrección. Requiere para su buen funcionamiento que las variables una vez ajustadas, no varíen en el tiempo, fundamentalmente es un controlador que hace variar la oferta, sin conocer la demanda [10].

Son los sistemas de control en los que la salida no tiene efecto sobre la acción de control, en estos sistemas de control de lazo abierto la salida ni se mide ni se retroalimenta para compararla con la entrada (figura 2.8).




Figura 2.8 Diagrama de Bloques, Lazo Abierto.

Donde tenemos $r(t)$ es la referencia o valor deseado, $u(t)$ acción de control (variable manipulada) y $y(t)$ salida del proceso (variable controlada).

3. Sistema de Control de Lazo Cerrado Realimentado: es un sistema de control que permanentemente está calculando el error por medio del controlador efectuando una acción correctora dependiendo de la magnitud de tal error. La señal de error actuante, la cual es la diferencia entre la señal de entrada y la de realimentación (esta puede ser la señal de salida), entra al controlador para reducir el error y llevar la salida del sistema a un valor deseado [10]. El término lazo cerrado implica que siempre este el uso de la acción de control retroalimentado esto para reducir el error del sistema. Este sistema está compuesto por el proceso, un elemento de medición, un controlador y un elemento final de control (figura 2.9).




Figura 2.9 Sistema de Control de Lazo Cerrado Realimentado.

Entendiendo los conceptos básicos y la teoría elemental del control se logrará obtener una visión más clara acerca del *control adaptativo*, este es un tipo especial de control, el cual consiste en adaptar los parámetros variables de un proceso a fin de mantener un funcionamiento adecuado, esto se usa cuando los parámetros o la estructura del modelo varía con el tiempo, lo cual se podría considerar como variables de perturbaciones internas [9]. Si un sistema de control cambia su comportamiento, debido a cambios de los parámetros del proceso, el control adaptativo se adapta.




Figura 2.10 Diagrama de Bloques, Control Adaptativo.

2.3.2 Modos de Control y Acciones Básicas

Existen diversos modos de controlar sistemas, estas acciones básicas complementan y definen lo complejo de un sistema a controlar. En el trabajo presente se emplearon dos acciones básicas del control *acción de control proporcional (P)* este es un modo de control en que el dispositivo corrector final (o accionador), tienen un rango continuo de posiciones posibles, con la posición exacta tomada siendo proporcional a la señal de error [9]; esto es la salida del controlador es proporcional a su entrada (fórmula 2.4)

$$Kp = \frac{U(s)}{E(s)} \quad (2.4)$$

$$Kp = K$$

Acción de Control Integral (I), en esta acción un controlador cuyo valor de salida varia en razón proporcional a la señal de error $e(t)$ acumulado [9]; lo que implica que es un modo de controlar lento (fórmula 2.5).

$$\frac{du(t)}{dt} = K_i e(t) \quad (2.5)$$

$$u(t) = K_i \int_0^t e(t) dt$$

donde K_i es igual a la ganancia integral.

La unión de ambas acciones de control genera un tipo de control de *Acción de Control Proporcional Integral (P-I)*. Un control P-I se define por la fórmula 2.6.

$$u(t) = K_p e(t) + \frac{K_p}{T_i} \int_0^T e(\tau) dt \quad (2.6)$$

donde:

T_i = *Tiempo integral* (K_i).

2.4 Modelos de Aprendizaje Estadísticos (AE)

Actualmente en los sistemas de automatización los modelos de aprendizajes estadísticos (AE) se han estado empleando como método alternativo de control, todo esto por medio de algoritmos matemáticos que realizan las operaciones de control a sistemas autómatas, siendo el objetivo de este proyecto de investigación el uso de los modelos de aprendizaje estadístico en los sistemas de barrido óptico. Los métodos estadísticos de aprendizaje van desde el simple cálculo de medias hasta la construcción de modelos complejos como las redes bayesianas o las redes neuronales, estos tipos de modelos tienen aplicaciones en informática, ingeniería neurobiología, psicología, física. El aprendizaje estadístico (AE) es un área de investigación muy activa, continuamente se hacen avances tanto en la teoría como en la práctica, hasta el punto que es posible aprender casi cualquier modelo.

2.4.1 Conceptos básicos Estadísticos

El entendimiento de los conceptos básicos de la estadística es necesario para la comprensión de los modelos matemáticos avanzados, las *variables Independientes* normalmente están asociadas a las entradas que pueda tener nuestra función (fórmula 2.7); función la cual se intentará modelar por los modelos de aprendizajes. El término “Variable” se utiliza para designar una cantidad susceptible de tomar distintos valores numéricos dentro de un conjunto de números específicos [18].

$$x = \{x_1, x_2, x_3, \dots x_n\} \quad (2.7)$$

A lo largo de esta investigación estas “Variables” serán el punto de enfoque, pues los modelos de aprendizajes estadísticos generaran diferentes procesos matemáticos, de los cuales se hablarán más adelante en la investigación. De igual forma existen las *Variables dependientes* que son aquellas cuyos valores dependen de los que tomen otras variables u otra variable (fórmula 2.8). Estas variables suelen representarse por “y”, son variables de respuesta que se observan en el estudio de un fenómeno y que podrían estar influidas por los valores de variables independiente (x) [8].

$$y = f(x) \quad (2.8)$$

Las variables dependientes es el factor que es observado y medido para determinar el efecto de las variables independientes.

En la estadística este conjunto de variables se puede ver como *muestras* las cuales podrían definirse como el subconjunto de casos o individuos de una población. El objetivo de seleccionar muestras es poder inferir propiedades de la totalidad de la población, o de un conjunto de datos [18]. En la investigación manejaremos la muestra con la siguiente estructura:




Figura 2.11 Estructura de una Muestra.

En la figura 2.11 podemos comprender que las muestras serán utilizadas como vectores de tamaño $[n \times 1]$ o $[1 \times n]$, dependiendo de cómo el algoritmo requiera trabajar la muestra. Cada muestra contiene las variables independientes (x) óseas las entradas de la función, y su variable dependiente ($f(x)$) ósea la salida de la función.

Los *banco de datos* o también llamados base de datos, son referidos a la totalidad de población de la cual se pueden extraer las muestras [7], también los bancos de datos o base de datos son conjuntos de datos o en nuestro caso particular muestras pertenecientes a un mismo contexto y almacenados sistemáticamente para su posterior uso [6].




Figura 2.12 Descripción grafica de un conjunto de datos almacenados en un banco de datos,

(a) Variables independientes y dependientes. (b) Muestra. (c) Banco de datos.

Como se muestra en la figura 2.12 podemos observar, que el tamaño del banco de datos será dependiente al número (k) muestras que se almacenen y al número (n) variables que contengan cada muestra, dejando como tamaño a la base de datos en $[k \times n]$.

Una técnica muy utilizada es la *estandarización de datos o normalización* esto se da cuando los datos están distribuidos con frecuencias ascendentes aproximadamente simétricas se le llama distribución normal [8], por lo tanto es simétrica respecto a su media, es posible relacionar todas las variables normales con la distribución normal estándar.



Figura 2.13: Distribución Normal (*curva normal*)

Por lo dicho con anterioridad, los datos pertenecientes a una distribución normal se pueden estandarizar o normalizar (fórmula 2.9).

$$Z = \frac{x - \bar{x}}{s} \quad (2.9)$$

Donde x es el valor nominal del dato a normalizar o estandarizar, $\bar{x}$ es la media del conjunto de datos, s es la desviación estándar de las variables, z son los valores resultantes de la operación de estandarización. Estos valores nos permitirán usar la desviación estándar como regla para medir la distancia estadística de la media, si los valores z son negativos, el valor de la variable independiente se encuentra por debajo de la media, en el caso donde z sea positivo el valor esta sobre la media.

Una forma de evaluar resultados en la estadística es la técnica de *validación cruzada*. Esta técnica es utilizada para evaluar resultados de análisis estadísticos y garantizar que son independientes las particiones entre datos de entrenamiento y prueba. Es un proceso muy sencillo de implementar, esto consiste de repetir y calcular la media obtenida de las medidas de evaluación sobre cada diferente partición [18]. El objetivo principal es poder evaluar la precisión de un modelo, esta técnica es muy utilizada en proyectos de inteligencia artificial.

Este proceso consiste en dividir en dos subconjuntos una base de datos que contienen las muestras a procesar, uno de los subconjuntos normalmente denominado datos de entrenamiento o muestras de entrenamiento se usará para realizar los pasos de entrenamiento y validación del modelo estadístico empleado; el otro subconjunto denominado datos de prueba o muestras de prueba, se utilizará para la prueba de evaluación del modelo [18] (figura 2.14), está claro aclarar que este subconjunto nunca fue analizado por el modelo estadístico, por lo tanto se garantiza que son independientes los datos de entrenamiento y los de prueba.




Figura 2.14 Descripción grafica de Validación Cruzada a) Gris-base de datos.

b) Azul-subconjunto de muestras de entrenamiento.

c) Rojo-subconjunto de muestras de prueba.

Existen diferentes tipos de validaciones cruzadas, de las cuales todas funcionan base el mismo objetivo anteriormente explicado, estos tipos de validaciones son presentados a continuación:

- Validación cruzada de K iteraciones

En este tipo de validación los datos de muestra se dividen en K subconjuntos, donde se toma uno de los subconjuntos para datos de pruebas, y el resto de $K-1$ subconjuntos son usados como datos de entrenamiento [18]. Este proceso se repite durante las K iteraciones, con cada uno de los posibles subconjuntos de prueba. Para finalizar se calcula un error de predicción, esto se genera en cada K iteraciones, el resultado final lo obtenemos por medio de la media de los K valores de error obtenidos (fórmula 2.10).

$$E = \frac{1}{K} \sum_{i=1}^K E_i \quad (2.10)$$

- Validación cruzada aleatoria

Este método consiste de dividir aleatoriamente el conjunto de datos de entrenamiento y el conjunto de datos de pruebas [18]. La ventaja de este método es que la división de datos de entrenamiento y de prueba no depende del número de iteraciones, la desventaja clara es que en este método pueden quedar muestras sin evaluar y otras muestras se pueden evaluar más de una vez. El error se calcula de misma manera que validación cruzada de K iteraciones fórmula 2.10.

- Validación cruzada dejando uno fuera

Este método implica separar los datos de manera que para cada iteración tengamos solo una muestra para los datos de prueba y todo el resto de muestras pertenezca a los datos de entrenamiento, con esto se garantiza un error bajo pero con un costo computacional alto, pues el número de iteraciones es igual a numero de N muestras se tengan [18]. El error calculado para este método se obtiene por la fórmula 2.11.

$$E = \frac{1}{N} \sum_{i=1}^N E_i \quad (2.11)$$

En el presente trabajo se implementa la validación cruzada de K iteraciones, por su alta confiabilidad y su manejo practico, permitiendo asegurar la separación independiente de las muestras de entrenamiento y muestras de pruebas.

En el AE existe el termino de *métricas de error* son medidas estadísticas para cuantificar la magnitud de una variable [6], las 2 métricas empleadas en la investigación, la primera métrica es el Error Cuadrático medio, conocidas por sus siglas en ingles MSE (Mean Square Error) y la segunda es la Raíz Cuadrada del Error Cuadrático medio de igual manera por sus siglas en ingles RMSE (Root Mean Square Error).

- Error Cuadrático Medio (MSE)

Este error en estadística es un estimador que mide el promedio de los errores al cuadrado, en otras palabras, es la diferencia entre un valor del estimador ($\hat{Y}$) y un valor que real (Y) (fórmula 2.12) [7]. Hay que tomar en cuenta que el MSE es una función “engañosa” pues el resultado que corresponde a la diferencia entre los valores de predicción y los valores reales son elevados al cuadrado para evitar valores negativos, pero esto también puede confundir o hacer perder la visión de cuan real es el error.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2 \quad (2.12)$$

- Raíz Cuadrada del Error Cuadrático Medio (RMSE)

Este tipo de métrica se utiliza frecuentemente cuando dos conjuntos de datos (valores teóricos y valores reales) son comparados, esta métrica representa desviación entre las diferencias de los dos conjuntos (fórmula 2.13) [8]. Como se puede ver en la fórmula 2.10 es el mismo valor de MSE pero se le aplica raíz cuadrada.

$$RMSE = \sqrt[2]{\frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2} \quad (2.13)$$

$$RMSE = \sqrt{MSE}$$

Notar que el valor de RMSE puede ser falso cuando $MSE < 1$, esto se presenta por el motivo que al aplicarle raíz cuadrada a un número menor a 1 este aumenta en vez de disminuir.

El *Coeficiente de Correlación* es otra técnica usada para medir la relación lineal entre dos variables [7], esto nos indica la intensidad o grado de dependencia entre las variables [8], en nuestro caso hablaremos de las variables ($\hat{Y}$) y (Y). Este valor es obtenido a través de la fórmula 2.14:

$$R = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{\hat{Y}}) * (Y_i - \bar{Y})}{s(\hat{Y}) * s(Y)} \quad (2.14)$$

Donde $\bar{\hat{Y}}$ y $\bar{Y}$ son la medias de las variables a evaluar y s es la desviación estándar de las variables $\hat{Y}$ y Y (fórmula 2.14). Este valor que se obtiene puede variar en el intervalo comprendido entre $[-1, +1]$.

- Si $R=1$, esto quiere decir que existe una correlación positiva perfecta entre las variables [8], en otras palabras cuando una de las variables aumenta la otra también, esto las hace en proporción constante.
- Si $0 < R < 1$, existe una correlación positiva.
- Si $R=0$, esto nos indica que no existe una relación lineal, una independencia total de los valores de las variables [8].
- Si $-1 < R < 0$, existe una correlación negativa.
- Si $R = -1$, podemos determinar que existe una correlación negativa perfecta, esto nos indica una dependencia total entre las dos variables pero inversamente, esto se le llama relación inversa [8]; cuando el valor de una variable aumenta la otra disminuye en proporción constante.

2.4.2 Mínimos Cuadrados Parciales (PLS)

En esta sección se discutirá sobre uno de los algoritmos de AE propuestos en la investigación; los mínimos cuadrados parciales la regresión por medio de mínimos cuadrados parciales o “*Partial least square regression*” conocida por sus siglas PLS, es un método estadístico que tiene relación con la regresión de componentes principales y la regresión múltiple [18]. Lo que se trata de encontrar es una regresión lineal mediante la proyección de las variables de predicción y las variables observables a un nuevo espacio [26]. Los PLS generan un análisis de componentes principales (PCA), en primer lugar, extraer un conjunto de factores latentes que explica en la mayor medida posible la covarianza entre las variables dependientes e independientes, después un paso de regresión pronostica los valores de las variables dependientes mediante la descomposición de las variables independientes [19].

Con el objeto de poder obtener un modelo en un espacio de menor dimensión que maximice la covarianza entre una matriz independiente X (matriz de predicción) y otra matriz dependiente de Y (matriz predicha), donde los elementos de la matriz X son las observaciones.

Modelo PLS

Existen m variables independientes $X_1, X_2, \dots, X_m$ donde existen p variables dependientes $Y_1, Y_2, \dots, Y_p$, se dispone de n observaciones y se desea ajustar un modelo de regresión, teniendo una matriz $Y_{n \times p}$ y $X_{n \times m}$.

La idea es poder descomponer en factores latentes T y U tal que:

$$Y = UQ' + F$$

(Fórmula 2.15)

$$X = TP' + E$$

donde T y U son matrices de $n \times a$, que contiene las componentes latentes o proyecciones de X (X score) y proyecciones de Y (Y score) de las n observaciones, por otra parte $Q = p \times a$, (Y loading) y $P = m \times a$, (X loading) son matrices de coeficientes. E y F son los términos de error.




Figura 2.15: Modelo PLS: T (X score), U (Y score), Q (Y loading), P (X loading)

Con todos estos datos se puede continuar a la predicción de $\hat{Y}$. La $\hat{Y}$ predicha se calcula como:

$$\hat{Y} = X * B \text{ (Fórmula 2.16)}$$

donde B es generada por la fórmula 2.14:

$$B = T * Q' \quad (2.17)$$

$$Q' = (T'T)^{-1} T'Y$$

$$T = Xw$$

$$w = cov(Y, X), \quad w = \frac{w}{\|w\|}$$

Regresión Simple:

En el caso que se presenta a continuación la matriz de variables dependientes se reduce a un vector de dimensiones n . El PLS puede considerarse como una transformación de las variables independientes, teniendo en cuenta su relación con la variable dependiente.

A continuación se presenta el pseudocódigo para la obtención de los componentes PLS:

Algoritmo 1: Pseudocódigo de PLS.

1. Entrada de datos: $X_{n \times m}, Y_{n \times 1}$
 2. // ciclo de n veces, obtención de componentes
 3. **for** $i=1$ **to** n
 4. $w = cov(Y, X), w = \frac{w}{\|w\|}$
 5. $T = X w$
 6. $Q = (T'Y) / (T'T)$
 7. $P = (T'W) / (T'T)$
 8. $X = X - TP = X - \hat{X}$
 9. $Y = Y - TQ = Y - \hat{Y}$
 10. **end i**
-

En los pasos 4 y 5 es uno de los pasos esenciales del método, la variable latente se conforma a partir de la covarianza entre las variables independientes (X) y la variable dependiente (Y). Los pasos 6 y 7 es fácil visualizar Q es el coeficiente de regresión simple de Y sobre T y P es un vector de dimensión m cuyas componentes son los coeficientes de regresión simple de cada variable X_i sobre T . Pasos 8 y 9 son las actualizaciones de los valores.

Notar que el algoritmo expuesto es interactivo y en cada interacción calcula un componente latente.

2.4.3 Redes Neuronales Artificiales (RNA)

Otro algoritmo de AE propuesto en la investigación a analizar son las redes neuronales artificiales (RNA) o en ingles como “*Artificial Neuronal Network*” “ANN” están inspiradas en la forma en que funciona el sistema nervioso biológico, en especial el del cerebro humano [14], que es completamente distinto al funcionamiento de un computador digital, el cerebro humano corresponde a un sistema altamente complejo, no-lineal y paralelo, el cual puede realizar muchas operaciones simultaneas a diferencia de las computadoras convencionales que son secuenciales [12].

Las RNA son un sistema de interconexión de neuronas que colaboran entre sí para producir un estimulo de salida.

Modelo Neuronal

En la figura 2.16 se presenta el modelo de una neurona simple, el objetivo de esto es poder modelar correctamente el comportamiento global de una red, comprendiendo desde la neurona hasta el conjunto de varias de ellas [13].




Figura 2.16 Modelo de una neurona sencilla

La figura 2.6, muestra como la neurona se compone de: valores escalares de entradas p , estas entradas normalmente son las variables independientes (X), las cuales son multiplicadas por los pesos de entrada (w) asociados a la neurona, esto forma un producto escalar que después se le suma la bias (b) asociada a la neurona [22]. Una vez esto tenemos un valor escalar n el cual pasa por la función de transferencia (f) donde se produce un valor final escalar (a).

$$a = f(wp + b) \text{ (fórmula 2.18)}$$

Los nombres empleados para estos tres procesos son:

- *Función de pesos*, en muchos tipos de redes neuronales esta función, es la multiplicación de los pesos w con la entrada p , pero en otras la función de pesos es una distancia entre los pesos w y las entradas p ($|w - p|$) [22].
- *Función de entrada de la red*, de igual manera muchas redes neuronales utilizan la sumatoria de los productos de entrada ($w * p$) mas la bias (b) pero otras usan la multiplicación [22].
- *Función de transferencia o activación*, estas funciones transmiten la idea de “on” y “off” dependiendo de la entrada, permitiendo que la neurona se active o no. Las funciones de activación o de transferencia tienen que estar acorde con el tipo de numero que van a recibir

en la capa de entrada [22]. La función de transferencia lineal figura (a), esta se emplean en la capa de salida de redes neuronales multicapas, como funciones de aproximación. La función de transferencia tangente hiperbólica (b), esta es empleada cuando se esperan valores entre $[-1,1]$, de igual manera empleado en funciones de aproximación. Otra función empleada es la función de transferencia sigmoidal (c), esta función es empleada en mayormente en problemas de clasificación pues regresa valores entre $[0, 1]$ (figura 2.17).




Figura 2.17: Función de transferencia: (a) función lineal, (b) función tangente hiperbólica, (c) función sigmoidal

La *arquitectura de la red neuronal* consiste de dos o más neuronas que pueden ser combinadas por capas, armando diferentes redes que contienen una o más capas ocultas, de esta forma pueden existir diversas combinaciones de redes en una sola red neuronal [13]. En la figura 2.18, se muestra una red neuronal compuesta de solo una capa oculta, donde las variables de entrada P_R están conectadas a cada neurona interna de la capa oculta por cada peso correspondiente a la neurona $w_{R,S}$, sumándole la bias (b_s) correspondiente a la neurona, esto da como resultado n_s resultados, los cuales entran a la función de transferencia f generando a_s resultados como neurona hubiese.




Figura 2.18: Arquitectura RNA, una capa oculta.

También la figura 2.18 puede ser visualizarse de forma matricial (figura 2.19), de esta se visualiza el proceso que se lleva dentro de la neurona:




Figura 2.19: Proceso matricial una capa oculta

Este proceso se repite por capas ocultas que se tengan, solo que las variables de salida (a_s) serán las variables de entradas de la siguiente capa oculta P . En la figura 2.20 se muestra como se da este proceso:




Figura 2.20 RNA con tres capas ocultas.

De esta forma, se puede tener un modelo el cual describe a nuestra RNA generada. Figura 2.21.




Figura 2.21: Proceso matricial tres capas ocultas

Como podemos observar nuestra última variable de salida a^3 es equivalente a nuestra variable dependiente Y , por lo tanto $a^s = Y$, donde s es el número de capas ocultas.

Los modelos de RNA multicapa son bastantes poderosos, normalmente se emplean con dos capas ocultas para el uso de funciones de aproximación, donde la primer capa contiene la función de activación sigmoideal y la segunda capa contiene una función de activación lineal [22].

2.4.4 Máquina de Vectores de Soporte

En esta sección se hablará del tercer algoritmo de AE propuesto en la investigación. Las Maquinas de vectores de soporte o maquinas de soporte vectorial (Support Vector Machines, SVM) es un método empleado en problemas de regresión y clasificación [15], las SVM son un sistema de aprendizaje basado en el uso de un espacio de hipótesis de funciones lineales en un espacio de mayor dimensión inducido por un Kernel [17], mas formalmente, una SVM construye un hiperplano o conjunto de hiperplanos en un espacio de dimensionalidad muy alta que puede ser utilizado en regresión o clasificación.

Función Kernel

Las funciones Kernel ofrecen una proyección a la información a un espacio de características de mayor dimensión el cual aumenta la capacidad computacional de las máquinas de aprendizaje lineal. Primeramente una forma más común en que las maquinas de aprendizaje lineal aprenda funciones es cambiando la representación de la función, esto es similar a “mapear” el espacio de las variables de entrada X a un nuevo espacio de características o atributos [23].

Para ilustrar este proceso podemos observar la figura 2.22 donde se muestra un mapeo de un espacio de entradas de dos dimensiones a un espacio característico de dos dimensiones.




Figura 2.22 (a) mapeo de un espacio de entradas, (b) mapeo a un espacio característico

También podemos observar que la información no puede ser separada por una máquina lineal en el espacio de entrada, mientras que en el espacio de características es más sencilla la separación. Con esto entendemos que:

$$x = \{x_1, x_2, \dots, x_n\} \rightarrow \varphi(x) = \{\varphi(x)_1, \varphi(x)_2, \dots, \varphi(x)_n\}$$

Podemos definir al Kernel (K) como una función, tal que para todo $x, z \in X$.

$$K(x, z) = \langle \varphi(x) \cdot \varphi(z) \rangle = \sum_{i=1}^l \varphi_i^T(x) \varphi_i(z) \quad \text{Fórmula 2.19}$$

Donde φ es un mapeo del espacio de entradas X al espacio de características F . El uso de la función Kernel hace posible el mapeo de la información de entrada (x, z) al espacio de características $\langle \varphi(x) \cdot \varphi(z) \rangle$ de forma implícita y poder entrenar el modelo en dicho espacio [15].

Existen diferentes tipos de funciones Kernel:

- *Kernel lineal*, es una transformación lineal del tipo (fórmula 2.20)

$$K(x, z) = \langle Ax \cdot Az \rangle = x^T A^T A z = x^T B z \quad (2.20)$$

Donde $B = A^T A$.

- *Kernel polinomial*, El mapeo polinomial es un método muy popular para modelar funciones lineales (fórmula 2.21)

$$K(x, z) = \langle Ax \cdot Az \rangle^d \quad (2.21)$$

- *Kernel de Base Radial*, estas funciones también son conocidas como función Gaussiana (fórmula 2.22).

$$K(x, z) = \exp(-\|x - z\|^2 / \sigma^2) \quad (2.22)$$

Arquitectura SVM para Regresión.

SVM tiene como meta encontrar la función $f(x)$ que tenga a lo mas una desviación ϵ_v de la salida para todos los datos de entrenamiento, y al mismo tiempo, que sea lo más mínima posible.

$$f(x) = \langle w \cdot x \rangle + b$$

(Fórmula 2.23)

$$f(x) = \langle x^T \cdot w \rangle + b$$

$$f(x) = \sum_{i=1}^n w_i x_i + b$$

Donde $\langle \cdot \rangle$ es el símbolo del producto interno, $x = \{x_1, x_2, \dots, x_n\}$ y $w = \{w_1, w_2, \dots, w_n\}$ donde w es el vector de pesos y b es el bias, en el caso 2.23 se busca encontrar w lo más mínima posible [16]. Para asegurar esto, una forma es minimizar la norma Euclidiana (fórmula 2.24).

$$\text{Minimizar } \frac{1}{2} \|w\|^2$$

(2.24)

Sujeto a:

$$y_i - (\langle w \cdot x_i \rangle + b) \leq \epsilon$$
$$y_i - (\langle w \cdot x_i \rangle + b) \geq -\epsilon$$

La idea básica de esto consiste en realizar un mapeo de los datos de entrenamiento $x \in X$, a un espacio de mayor dimensión F a través de un mapeo no lineal $\varphi: X \rightarrow F$, donde podemos realizar una regresión lineal, en la figura 2.23 se puede apreciar la arquitectura generada por la SVM para regresión.




Figura 2.23 Arquitectura SVM- Regresión

El resultado que se obtiene de esto es Y , quien viene siendo el valor de predicción de la SVM-Regresión, la fórmula 2.25 demuestra la ecuación matemática.

$$y = \sum_{i=1}^{sv} \omega_i K(x_i, x) + b \quad (2.25)$$

3.1 Materiales

A continuación se describirán los materiales empleados en la experimentación. Las pruebas fueron implementadas a través de dos diferentes programas de computadora: en la etapa de control y automatización del sistema de barrido óptico, se empleó el programa National Instruments LabVIEW 2010® (32 bits); en las etapas de implementación, selección de parámetros y extracción del modelo de aprendizaje estadístico se empleó el programa MATLAB R2011a® (64 bits).

Ambos programas fueron ejecutados en computadoras de escritorio con las siguientes características: procesador Intel® Cores™ i3 M 330@ 2.13GHz, con una memoria RAM 4.00 GB (3.80 GB usable), con un sistema operativo de 64-bits.

Datos Empleados en la Experimentación.

Los datos utilizados están conformados por 9373 muestras, que consisten de dos variables independientes: ángulo (x_1) y distancia (x_2), teniendo solo una variable de salida o variable dependiente, frecuencia (y). La variable independiente “ángulo” contiene valores a partir de $5^\circ \leq x_1 \leq 115^\circ$ y la variable independiente “distancia” con valores de $9\text{ cm} \leq x_2 \leq 142\text{ cm}$.

Los datos fueron obtenidos por medio del programa de computadora National Instruments LabVIEW 2010®. La adquisición de los datos se obtuvo de la siguiente manera: el emisor de luz se desplazaba a través de ángulos de 5° y se alejaba a diferentes distancias (cm) del barrido óptico. Por cada cambio a los valores de las variables se ajustaba manualmente la frecuencia hasta encontrar la frecuencia óptima asociada a la velocidad del motor respecto al ángulo y la distancia a la que se encontraba el emisor de luz, después se procedió a capturar y almacenar los nuevos valores de las lecturas.

La base de datos se trabajó en 2 subconjuntos: base de datos entrenamiento y base de datos prueba. La base de datos de entrenamiento (TRN) consiste de un 80% de los datos totales repartidos para el entrenamiento y validación de los algoritmos matemáticos de AE. La base de datos de prueba (TST) esta generada por el otro 20% restante de los datos totales, estrictamente usados para pruebas finales de los algoritmos. En pruebas de AE se busca que los datos de

entrenamiento y los datos de prueba presenten la misma naturaleza y distribución de la información que los conforman, en la figura 3.1 se observa dicha división de datos y su comportamiento.




Figura 3.1 Comportamiento de los datos de prueba y datos de entrenamiento.

3.2 Métodos

En esta sección se describirán los métodos y los procesos empleados en el proyecto, de tal manera se mostrará un diagrama a bloques del procedimiento seguido en esta sección 3.2, esto con el fin de visualizar de manera gráfica y global todo el proceso empleado. Posteriormente se pasará a la descripción de cada bloque del diagrama:




Figura 3.2 Descripción grafica de la experimentación.

Etapas 1: Adquisición de Datos.

En la primera etapa se generó una base de datos, con la que se trabajó a lo largo del proyecto. Como anteriormente fue descrito, los datos están conformados por 9373 muestras.

Etapas 2: Desarrollo de un Sistema de Control de Lazo Cerrado.

En la segunda etapa se implementó un control de lazo cerrado utilizando el programa de computadora National Instruments LabVIEW 2010®, controlando la variable *frecuencia* del motor y permitiendo al usuario trabajar con el prototipo de manera controlada y estable.

Al desarrollar un sistema de control de lazo cerrado se propuso la implementación del controlador P-I, donde el control proporcional (P) indicaba cuanto equivale el error $e(t)$ respecto a la señal empleada y, el control integral (I) entregaba el valor de salida en razón proporcional a la señal de error $e(t)$ acumulada. De tal manera, trabajando estos dos tipos de control (proporcional e integral) en conjunto, se obtuvo como resultado un control proporcional integral.

Para poder generar un control proporcional es necesario conocer la relación lineal respecto a la variable manipulada y la variable controlada, esto se puede lograr revisando las especificaciones

del motor de giro empleado para el sistema de barrido óptico. Al carecer de esta información se procedió a generar una tabulación, donde se pudiera observar la relación lineal entre la variable manipulada (Voltaje) y la variable a controlar (Frecuencia).

Relación lineal Variable Manipulada, Variable Controlada

Voltaje (Variable Manipulada)	Frecuencia (Variable Controlada)
0.300 v	10 Hz
0.335 v	20 Hz
0.370 v	30 Hz
0.405 v	40 Hz
0.440 v	50 Hz
0.475 v	60 Hz
0.510 v	70 Hz

Tabla 3.1 Relación lineal Voltaje del motor y frecuencia del motor.

Los datos de la tabla 3.1, nos indican que por cada 0.035v el motor aumenta su frecuencia de rotación en 10 unidades, por lo tanto con una simple regla de 3 podemos hallar cuanto equivale el aumento de 1Hz en voltaje, esto nos da 0.0035 v por Hz. Con esta información se adquiere la relación de la variable manipulada y la variable controlada figura 3.3.




Figura 3.3 Relación Voltaje-Frecuencia motor

Es importante recordar que debido a las propiedades físicas del motor, éste requiere de un voltaje y corriente mínima de excitación, por lo tanto es necesario en primera instancia generar estos valores de excitación para poder después controlarlos a voluntad.

El control proporcional generó la relación de las variables manipuladas con respecto a la variable controlada. Como resultado de esto, es necesario generar un control integral con el fin de poder

dar una sumatoria o resta (dependiendo del error), respecto a un error obtenido de la señal de referencia y la señal de salida.




Figura 3.4 Control Integral Frecuencia-Frecuencia

Una vez implementados los dos tipos de control mencionados anteriormente, se genera el Control Proporcional Integral. En la figura 3.5 se observa el sistema de bloques sin retroalimentación a la izquierda y el sistema con retroalimentación a la derecha.




Figura 3.5 Implementación de Control de Lazo Abierto a Control de Lazo Cerrado.

Como muestra la figura 3.5 tenemos $r(t)$ que es la referencia o valor deseado, en nuestro caso sería la frecuencia del motor, $u(t)$ es la acción de control (variable manipulada) la cual es el incremento o decremento del voltaje al motor, que es linealmente proporcional a la frecuencia del mismo, es decir, al incrementar el voltaje del motor aumenta su frecuencia y si disminuye el voltaje lo hará la frecuencia. $y(t)$ es la salida del proceso (variable controlada), que es la frecuencia en que se encuentra el motor operando. En el control de lazo cerrado se puede encontrar $e(t)$ (señal de error) que es la diferencia entre la señal de referencia y la señal de salida real, en nuestro caso es la diferencia entre la frecuencia solicitada por el usuario y la frecuencia real que se encuentra el motor operando.

Etapas 3: Ejecución de los Algoritmos de Aprendizaje Estadístico

Los tres algoritmos de aprendizaje estadístico fueron implementados y ejecutados en el programa de computadora de MATLAB R2011a® (64 bits). Algunas consideraciones fueron tomadas en cuenta para cada uno de ellos en función de su cálculo particular:

1. PLS- La implementación de este modelo de aprendizaje estadístico, fue con funciones propias del MATLAB R2011a. Este tipo de modelo de AE no requiere ningún tipo de validación, los PLS no requieren de parámetros a modificar, este algoritmo trabaja respecto a los datos de entrada y los datos de salida del banco de datos que se le entregue. Calcula los factores latentes de la base de datos y por esta manera no requirió ningún tipo de ajuste.

2. RNA-. En la implementación de las redes neuronales se uso el “Neural Network Toolbox” de MATLAB R2011a, con el cual se gestó la red neuronal, ejecutando las funciones de entrenamiento y de prueba, que brinda esta herramienta.

El método empleado en la selección de los parámetros fue el método de búsqueda de grilla, y en el método de validación fue por validación cruzada de K iteraciones. Con estos métodos se garantiza la independencia de los datos de entrenamiento y los datos de validación. A partir de esto los datos de entrenamiento fueron separados por validación cruzada de 10x10, generando así 100 ciclos de muestras diferentes para cada entrenamiento y validación hechas por la red neuronal, que a su vez por cada ciclo se genera la búsqueda de grilla, que va cambiando los parámetros de construcción de la red neuronal, arrojando como producto final 300 datos de información respecto a la métrica de MSE de validación.

Los Parámetros a variar con la búsqueda de grilla:

- Estrategias de aprendizajes (Levenberg Marquardt Backpropagation (LM), Quasi-Newton Backpropagation (BFG), RPROP Backpropagation (RP))

Valores Constantes en la búsqueda de grilla:

- Capas ocultas=1
- Numero de neurona por capa oculta=2
- Numero de neurona en capa de salida=1
- Función de transferencia en capa oculta= función tangente hiperbólica
- Función de transferencia en capa de salida=función lineal

3. SVM- En la implementación de las SVM se usaron dos librerías en MATLAB R2011a, “LIBSVM” ([27]) y “PRTool” ([28]). La librería LIBSVM fue usada en el ciclo de entrenamiento, validación, selección de parámetros y en pruebas.

El método empleado para la selección de los parámetros fue el método de búsqueda de grilla, y el método empleado para la justificación de los datos fue la validación cruzada de K iteraciones, mismo que se usó en RNA (anteriormente explicado), dando como resultado los datos de información respecto a la métrica de MSE de validación.

Los Parámetros a variar con la búsqueda de grilla:

- Función de mapeo (Kernel lineal, Kernel polinomial, Kernel Base radial).
- Valor de grado polinomial(Kernel polinomial)
- Valor de sigma ϕ (Kernel base radial)
- Valores de épsilon (ϵ)

Valores Constantes en la búsqueda de grilla:

- SVM-regresión.

Una vez seleccionados los mejores parámetros se procedió al ciclo de prueba, donde se generó un entrenamiento de las SVM con los parámetros óptimos y con la base de datos de prueba (TST), calculando el error de predicción (MSE y RMSE) y su coeficiente de correlación (R).

Etapas 4: Implementación del Algoritmo de Aprendizaje Estadístico por medio del Lazo Cerrado.

Se finalizó con la selección del mejor modelo de aprendizaje estadístico realizando su implementación en el sistema de control de lazo cerrado por medio del programa de computadora National Instruments LabVIEW 2010®, con el que se originó la interfaz de comunicación al prototipo de sistema de barrido óptico.

De igual forma cabe mencionar que los parámetros extras como el tiempo, consumo de memoria, etc. no fueron necesarios de evaluar debido a que se requiere un algoritmo que genere una alta exactitud de predicción para el correcto funcionamiento del sistema de barrido óptico.

4.1 Resultados experimentales

Desempeño de Algoritmos de Regresión.


En la Tabla 4.1 se presentan los resultados obtenidos de los errores de prueba por cada algoritmo de regresión (PLS, RNA y SVM). En esta se puede observar que el algoritmo de regresión SVM ofrece las mejores lecturas i.e. los errores de predicción más bajos, seguido por la RNA. El desempeño del algoritmo PLS es notoriamente inferior a los dos anteriores. Por otra parte, el análisis estadístico clásico indica que tanto las respuestas o predicciones de la SVM y la RNA *siguen* satisfactoriamente a los valores de respuesta verdaderos –i.e. R 's cercanos a uno.

	<i>MSE</i>	<i>RMSE</i>	<i>Coeficiente de Correlación</i>
<i>PLS</i>	$E=88.41$	$E=9.40$	$R=0.72$
<i>RNA</i>	$E=13.45$	$E=3.66$	$R=0.96$
<i>SVM</i>	$E=6.48$	$E=2.54$	$R=0.98$


Tabla 4.1 Errores en Etapa de Prueba por cada algoritmo de regresión análisis de regresión estadística clásico

En la figura 4.1 se presentan en la parte izquierda las graficas de los valores de predicción y los valores reales para cada uno de los algoritmos de regresión utilizados. En la parte derecha se presenta el análisis de regresión estadística clásico, de igual manera para cada uno de los algoritmos utilizados. Se puede notar claramente que los resultados obtenidos en las graficas concuerdan con la tabla 4.1 resultando el algoritmo SVM el de mejor desempeño..

PLS



RNA



SVM




Figura 4.1: Visualización de Valores de predicción y valores reales (parte izquierda) y análisis de correlación lineal por cada algoritmo de regresión.

Selección de Modelos

Tanto la SVM como la RNA poseen parámetros de ajuste por el usuario, como se detalló en el capítulo anterior. De tal manera que después de realizar experimentos con las posibles variantes de ellos, se obtuvo lo siguiente: Para el SVM, el kernel que ofreció los errores de predicción más bajos fue el *Kernel de Base Radial*, y para la RNA la estrategia de aprendizaje con mejores resultados fue la conocida como *Levenberg Marquardt Backpropagation* (LM). En la tabla 4.2 se muestran los mejores valores para el resto de parámetros para estos algoritmos:

RNA	Estrategia	Levenberg Marquardt Backpropagation (LM)
	Capas ocultas	1
	Neuronas en Capa oculta	2
	Neuronas en Capa de salida	1
	Función de Transferencia Capa oculta	Función Tangente Hiperbólica
	Función de Transferencia de Salida	Función Linear
SVM	Kernel	Base Radial
	Parámetro de Complejidad (C)	1000
	Sigma(Parámetro del Kernel)	0.001
	Épsilon (ϵ)	0.1

Tabla 4.2: Parámetros óptimos de la RNA y SVM.

Debido a que la SVM ofreció el mejor desempeño con respecto a los otros algoritmos de regresión, se realizó un preprocesamiento adicional a fin de mejorar sus lecturas experimentales. Este consistió en generar una limpieza de los datos con los que se entrenaba el modelo, y consistió de en eliminar muestras repetidas y posible ruido en las señales. En la Figura 4.2 se muestra una mejora consirable en en la predicción de la señal –parte izquierda— y un coeficiente de regresión R muy próximo a uno. Los valores para MSE y RMSE fueron 0.26 y 0.51 respectivamente.




Figura 4.2 SVM-Kernel Base Radial mejorado.

Implementación del mejor modelo de aprendizaje estadístico.

De esta manera el algoritmo seleccionado (SVM-Kernel Base Radial mejorado) fue implementado en el sistema de control retroalimentado –ver figura 4.3.




Figura 4.3 Sistema de Control Retroalimentado con Modelo matemático.

En la figura 4.4 se muestran imágenes de la señal Gaussiana del sistema de barrido sin retroalimentación (parte izquierda) y con retroalimentación (parte derecha).




Figura 4.4 Señal Gaussiana sin retroalimentación (parte izquierda) y con retroalimentación (parte derecha).

En las gráficas se puede apreciar la mejora notable en la señal gaussiana antes y después de acoplar el modelo matemático resultante. Se puede visualizar como las señales Gaussianas son suavizadas y mejorada la detección del centro energético, esto por el algoritmo de regresión SVM-Kernel Base Radial presentando un menor error en la detección del centro y más cercano a lo deseado en el sistema.

4.2 Discusión de resultados

La implementación de PLS no es el algoritmo más adecuado para solucionar el problema en particular. Se puede conjeturar que el bajo rendimiento de éste se debe a que el problema no es de naturaleza lineal. De esta manera se puede afirmar que otros tipo de algoritmos *similares* pueden presentar el mismo desempeño, como puede ser el caso de *Ridge Regression*, *Lasso* o un modelo de regresión multivariado clásico. Sin embargo es conveniente mencionar que, debido a la ausencia de parámetros de ajuste en este algoritmo, se resta cierta flexibilidad al modelo final. Situación que puede ser amortiguada, en el caso de *Ridge Regression* y *Lasso* al poseer estos parámetros de ajuste.

Con respecto a la RNA, si bien los resultados fueron aceptables ($MSE=13.45$ y $RMSE=3.66$), se fijaron otros parámetros que pudieron ser ajustados para incrementar su desempeño. Incrementar el número de capas internas y el número de nodos internos pueden ser dos estrategias a seguir.

Capítulo 5. Conclusiones

La implementación de algoritmos de aprendizaje estadístico en sistemas de controles electrónicos es ampliamente recomendable permitiendo aumentar la eficiencia de estos, como ha quedado plasmado en los resultados experimentales descritos en el presente documento. Estos resultados motivan a la aplicación de algoritmos inteligentes en una variedad de procesos industriales o comerciales donde se aplique algún tipo de automatización y control y no solo restringido ambientes de naturaleza electrónica.

En el caso bajo estudio los resultados antes obtenidos del centro energético presentaban un alto error, la señal del centro energético se encontraba desplazado a través de la señal Gaussiana, al implementar la retro alimentación con los algoritmos inteligentes en el sistema de barrido óptico mejoro la posición del centro en la señal.

Uno de los inconvenientes que se presentó durante la etapa experimental fue el tiempo de ejecución de los algoritmos y cada variante, sin embargo, esta problemática es relativa en el sentido de que el resultado deseado es un modelo matemático para su posterior implementación. A fin de mejorar el proceso de experimentación en este contexto, se puede hacer uso de estrategias de paralelismo para incrementar el desempeño computacional de manera significativa.

Se eligió el algoritmo de regresión PLS desde un inicio ya que la complejidad de la ecuación matemática es mínima, permitiendo esto una fácil implementación en circuitos electrónicos o su programación en diferentes lenguajes. Desafortunadamente sus resultados no fueron lo esperado, descartando este modelo como una recomendación viable para el contexto en el que se ha trabajado. Los resultados obtenidos en la SVM fueron superiores. La implementación del modelo matemático generado no atañe mayor complicación en sistemas de control.

La propuesta descrita en esta tesis se ha evaluado con un conjunto de datos de complejidad moderada, esto ha facilitado el desarrollo de la fase experimental del trabajo. Sin embargo, es conocido en la literatura científica que tanto RNA con SVM y en particular esta última, pueden lidiar con problemas de mayor complejidad o dimensionalidad. Tomando en cuenta esto, se puede decir que los modelos de aprendizaje estadístico tienen el potencial necesario para su implementación en áreas de ingeniería de control.

De manera que la implementación de los algoritmos de aprendizaje estadístico en procesos de tareas de tipo SHM es altamente recomendable, mostrando que los resultados del sistema de barrido óptico y sus señales obtenidas de él, eran los deseados permitiendo así reducir el error considerablemente que antes se tenía en la obtención del centro energético de la señal Gaussiana.

5.1 Trabajos Futuros

- Realizar un estudio comparativo de los tiempos ejecución entre los algoritmos en las etapas de pruebas.
- Implementar de estrategias de paralelismo para incrementar el desempeño de los algoritmos.
- Realizar pruebas experimentales con conjuntos de datos con complejidad y analizar los efectos que estos generen en la implementación del modelo.
- Implementar y analizar los algoritmos de aprendizaje en sistemas de barrido con doble apertura.

Bibliography

- [1] M. Domjain, Principios de Aprendizaje y Conducta, Cengage Learning, 2010.
- [2] M. A. Gluck, Aprendizaje y Memoria: del cerebro al comportamiento, McGraw- Hill, 2009 .
- [3] H. M. A. H. a. X. G. E. Rizk1, «“Structural health monitoring of slab-column connections using FBG sensors”,» 2010.
- [4] V. T. D. H.-B. M. R. L. I. R. L. L. D. C. O. Sergiyenko, «Precise Optical Scanning for practical multiapplications.,» de O. Sergiyenko, V. Tyrsa, D. Hernandez-Balbuena, M. Rivas López, I. Rendón López, L. Devia CrProceedings of IEEE-34th Annual Conference of IEEE Industrial Electronics (IECON'08),, Florida, 2008.
- [5] S. O. A. M. D. L. T. V. a. R. I. Rivas López Moisés, Rivas López Moisés, Sergiyenko Oleg, Aguirre Mario, DeviSpatial data acquisition by laser scanning for robot or SHM task., IEEE-IES Proceedings International Symposium on Industrial..
- [6] E. Kreyszing, Introduccion a la estadistica matemática: Principios y Métodos, Limusa, 2014.
- [7] R. P. Abelson, La estadística razonada: reglas y principios, Paidos, 1998.
- [8] R. E. Walpole, Probabilidad y estadística para ingeniería y ciencias, Pearson, 2012.
- [9] W. Bolton, Mecatronica : Sistemas de control electrónico en la ingeniería mecánica y eléctrica, Alfaomega , 2010.
- [10] N. S. NNise, Sistemasde Control para Ingeniería, CECSA, 2002.
- [11] Umez-Eronini, Dinamica de Sistemas y Control, Thomson Learning, 2001.
- [12] A. Ethem, Introduction to machine learning, MIT Press, 2004.
- [13] E. N. Sanchez Camperos, Redes neuronales: ConceptosFundamentos aplicaciones a control automatico, Peason Educacion, 2006.
- [14] J. R. Hilera Gonzalez, Redes Neuronales Artificiales: fundamentos, modelos y aplicaciones, Addison Wesley Iberoamericana, 1995.

- [15] L. Yizeng, SupportVector Machines and their application in chemistry and biotechnology, CRC Press, 2011.
- [16] V. Kecman, Learning an soft cumputing: support vector machines, neuronal networks, and fuzzy logic models, MIT, 2001.
- [17] C. Nello, An introduction to support ector machines and other kernel based learning methods, Cambridge University Press, 2000.
- [18] T. Hastie, The elements of statistical learning: data mining, inference and prediction., Springer, 2001.
- [19] H. D. W, Applied Logistic Regression, Wiley, 2000.
- [20] M. R. L. O. S. F. G. N. J. C. ,. H. B. W.Flores Fuentes, «Digital Signal Processing on Optoelectronic for SHM,» de *Proceedings of the World Congress on Engineering and Computer Science*, San Francisco, USA, 2013.
- [21] J. C. Bermejo Sergi, «Aprendizaje Estadístico- Redes Neuronales,» ETSETB- DEPARTAMENT D'ENGINYERIA, Catalunya, 2001.
- [22] M. H. Beale, «Neuronal Network Toolbox User's Guide,» The MathWorks, Inc, 2014.
- [23] R. S. Ureña, Maquinas de Vectores Soporte para reconocimiento robusto de habla, Madrid: Tesis Doctoral, 2011.
- [24] R. L. M., S. O. Yu, T. V.V., H. P. W., D. C. L.F, H. B. D. y N. H. J. I., «Optoelectronic Method for Structural Health Monitoring,» *SAGE publicatod*, vol. 9, 2010.
- [25] J. A. R. Trejo, Maquinas de Vectores de Soporte para identificacion en linea, Centro de Investigacion y de Estudios Avanzados del Instituto Politencnico Nacional, Mexico : Tesis Doctoral , 2006.
- [26] T. Fletcher, Support Vector Machines Explained, UCL, 2009.
- [27] C.-C. C. a. C.-J. Lin, LIBSVM -- A Library for Support Vector Machines, *Journal of Machine Learning Research* 6, 2005.
- [28] E. P. a. R. Duin, «PRTool,» Delft University of Technology, 2010.

A.1 Mínimos Cuadrados Parciales

```
close all; clear all; clc
load DATA

%STEP 1-Data separation
%*****
%Data train
X=data_train(:,1:end-1);
Y=data_train(:,end);
%Data test
X_test=data_test(:,1:end-1);
Y_test=data_test(:,end);
%*****
%STEP 2-Latents Factors
%*****
%T(Xscore), U( Yscore), P( Xloading), Q( Yloading), B(Beta);
%MATLAB funcion "PLSREGRESS"
[XL,Yl,XS,YS,beta,PCTVAR] = plsregress(X,Y,2);
%*****
%STEP 3- Prediction
%*****
Y_Prediction= [ones(size(X_test,1),1) X_test]*beta;
%*****
```

A.2 Redes Neuronales Artificiales

```
close all; clear all; clc;
load Data;

%STEP 1-Data separation
%*****
%DATA TRAIN
X=data_train(:,1:end-1);
Y=data_train(:,end);
%DATA TEST
Xtst=data_test(:,1:end-1)';
Ytst=data_test(:,end)';
inputs = X';
targets = Y';
%*****
%STEP 2- Neuronal Construction
%*****
% Numbers of Neural in hidden Layer
hiddenLayerSize = [2];
net = fitnet(hiddenLayerSize);
%Transfer Function
net.layers{1}.transferFcn = 'tansig'; %hidden Layer
net.layers{2}.transferFcn = 'purelin'; %Out Layer
%Preprocessing
net.inputs{1}.processFcns = {'removeconstantrows','mapminmax'};
```

```

net.outputs{2}.processFcns = {'removeconstantrows','mapminmax'};
net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'sample'; % Divide up every sample
net.divideParam.trainRatio = 90/100;
net.divideParam.valRatio = 10/100;
net.divideParam.testRatio = 0;
% Learning Strategy
net.trainFcn = 'trainlm'; % Levenberg-Marquardt
% PERFORMANCE FUNCTION
net.performFcn = 'mse'; % Mean squared error
% Neuronal Tools
net.plotFcns = {'plotperform','plottrainstate','ploterrhist', ...
'plotregression', 'plotfit'};
%*****
%STEP 3- Training Neural Network
[net,tr] = train(net,inputs,targets);
%*****
%STEP 3- Prediction
%*****
YT =sim(net,Xtst);
%*****

```

A.3 Maquina de Vectores de Soportes

```

close all; clear all; clc;
load Data

%STEP 1-Data separation
%*****
%DATA TRAIN
X=data_train(:,1:end-1);
Y=data_train(:,end);
%DATA TEST
X_test=data_test(:,1:end-1);
Y_test=data_test(:,end);
%*****
%STEP 2- SVM parameters
%*****
[Model_SVM] = svmtrain(Y,X,['-s 3 -t 2 -c 1000 -g 0.001 -p 0.1 -v 3 -n 2e-08']);
%*****
%STEP 3- Prediction
[YpredBest, OAtest, decisions] = svmpredict(Y2,X_test,Model_SVM);
%*****

```

A.4 Resultados de Búsquedas de Grilla y Validación Cruzada


Resultados-Redes Neuronales Artificiales

Promedio de error MSE de cada estrategia de aprendizaje implementado en la red neuronal en la validación cruzada de 10 x10 en la etapa de entrenamiento y validación.


Resultados de Validación Cruzada –RNA	
Estrategia de Aprendizaje	$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2$
LM	13.05
BFG	14.02
RP	14.85

Anexo Tabla 1. Resultado de validación Cruzada-RNA- MSE


Anexo figura 1 muestra los comportamientos que tuvieron las estrategias de aprendizaje implementadas en las redes neuronales.



(a)



(b)



(c)

Anexo Figura1: Resultados de validación cruzada (a) LM, (b) BFG, (c) RP.


Resultados-Máquinas de Vectores de Soporte

Los resultados obtenidos en la etapa de entrenamiento y en la etapa de validación se muestran a continuación, los resultados presentados en la figura 4.4 son los errores MSE de la validación cruzada

(solo los que tuvieron mejor desempeño por cada Kernel empleado)y en la tabla 4.5 se presenta el error MSE más pequeño localizado por parámetro empleado:

Resultados de Validación Cruzada -SVM	
Kernel Empleado	$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{Y}_i - Y_i)^2$
Lineal	88.63
Polinomial grado 2	62.30
Polinomial grado 3	64.08
Base Radial	10.14

Tabla 4.5 Resultados Validación Cruzada-SVM



Anexo Figura 2 Resultados de la validación cruzada (a) Kernel lineal (b) Kernel Polinomial grado 2
(c) Kernel Polinomial grado 3 (d) Kernel Base radial

A.4 Sistema Retroalimentado (LabVIEW)

