

**MODELO DE DETECCIÓN Y DIAGNOSTICO BASADO EN CONFIABILIDAD
PARA LA DETECCIÓN DE FALLAS EN LAS BOMBAS DE DIESEL PRODUCTO
HIDROTRATADO DE LAS UNIDADES DE HIDROTRATAMIENTO DE
COMBUSTIBLES DE ECOPETROL EN LA GRB**

FREDY EDGARDO MALDONADO FLÓREZ

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO MECÁNICAS
ESCUELA DE INGENIERÍA MECÁNICA
MAESTRÍA EN GERENCIA DE MANTENIMIENTO
BUCARAMANGA**

2019

**MODELO DE DETECCIÓN Y DIAGNOSTICO BASADO EN CONFIABILIDAD
PARA LA DETECCIÓN DE FALLAS EN LAS BOMBAS DE DIESEL PRODUCTO
HIDROTRATADO DE LAS UNIDADES DE HIDROTRATAMIENTO DE
COMBUSTIBLES DE ECOPETROL EN LA GRB**

FREDY EDGARDO MALDONADO FLÓREZ

**Trabajo de grado para optar el título de Magister en Gerencia de
Mantenimiento**

Director

CARLOS BORRAS PINILLA

PhD. Ingeniero Mecánico

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO MECÁNICAS
ESCUELA DE INGENIERÍA MECÁNICA
MAESTRÍA EN GERENCIA DE MANTENIMIENTO
BUCARAMANGA**

2019

DEDICATORIA

Dedico este trabajo a Dios, por permitirme estar vivo, lleno de bendiciones y permitirme ser una persona feliz.

A mis padres por darme la vida y el empujón para caminar en la vida, ganando experiencias y conocimientos.

A mi esposa Sandra y mis hijos Jhon y Juan, por ser la luz de mi vida y fuente de inspiración para poder crecer todos los días junto a ellos.

A mis hermanos por ser gran apoyo en mi vida y fuente de ejemplo.

A mi compañero de trabajo y estudio Juan Carlos Campillo, quien perdió su vida trabajando por su familia y el desarrollo del país.

AGRADECIMIENTOS

Agradezco a Dios primeramente por todas sus bendiciones y permitirme hacer realidad mi sueño de profesionalizarme y especializarme en mi carrera.

A Ecopetrol, por permitirme trabajar en esta gran empresa, en donde día a día crecemos más como personas y profesionales.

A mi Director por su grandioso e incondicional apoyo en la realización de este proyecto.

A mis amigos por su voz de aliento para realizar todos mis propósitos.

A mis compañeros de trabajo, que de una u otra forma han aportado a mi crecimiento.

A la Universidad Industrial de Santander, por permitirnos profesionalizarnos más con nuevas oportunidades académicas.

A los Profesores y Personal administrativo de la Facultad por su atención y apoyo prestado.

Gracias a todos.

CONTENIDO

	Pág.
INTRODUCCIÓN	20
1. GENERALIDADES DEL PROYECTO	21
1.1 PLANTEAMIENTO DEL PROBLEMA.....	21
1.2 HIPÓTESIS.....	24
1.3 OBJETIVOS.....	24
1.3.1 Objetivo general.....	24
1.3.2 Objetivos específicos:	24
1.4 JUSTIFICACIÓN.....	25
1.5 CONTEXTO	27
1.5.1 Descripción de la Empresa.	27
1.5.2 Grupo Empresarial Ecopetrol.....	28
1.5.3 Área de influencia de las Operaciones de Ecopetrol S.A.....	29
1.5.4 Portafolio de servicios y productos de ECOPETROL S.A.....	31
1.5.5 Estructura organizacional de ECOPETROL S.A.....	31
1.5.6 Localización Refinería Barrancabermeja Ecopetrol S.A.	34
1.5.7 Unidad de Hidrotratamiento de Diésel de la Refinería Barrancabermeja de ECOPETROL S.A.	36
1.6 METODOLOGÍA	39
2. ANÁLISIS DE LA LITERATURA RECOPIADA	41
2.1 MARCO TEÓRICO	41
2.1.1 Mantenimiento	41
2.1.2 Confiabilidad	41
2.1.3 Falla	42
2.1.4 Modo de falla	43
2.1.5 Tasa de Falla λ	44

2.1.6 Tiempo Medio entre Fallas MTTF	45
2.1.7 Mantenibilidad.....	45
2.1.8 Disponibilidad.....	46
2.1.9 Relación entre Confiabilidad, Mantenibilidad y Disponibilidad.	47
2.2 DETECCIÓN Y DIAGNOSTICO DE FALLAS	48
2.2.1 Sistemas expertos basados en Reglas.....	49
2.2.2 Sistemas Expertos Basados en caos.....	50
2.2.3 Sistemas basados en Razonamiento.....	52
2.2.4 Sistemas de Aprendizaje	52
2.2.4.1 Diagnostico y detección con modelos de análisis de señales.....	52
2.2.4.2 Diagnostico y detección con modelos del proceso.	53
2.2.4.3 Diagnostico y detección con modelos basados en razonamiento y sistemas de aprendizaje.	53
2.3 REVISIÓN BIBLIOGRÁFICA	54
2.4 REDES NEURONALES ARTIFICIALES.....	58
2.4.1 Historia de las Redes Neuronales Artificiales (ANN).	59
2.4.2 Tipos de Redes neuronales.	62
2.4.2.1 Red Neuronal Dinámica.....	63
2.4.2.2 Red Neuronal Feedforward o Perceptron Multicapa	64
2.4.2.3 Red Neuronal basada en retardos del tiempo.....	64
2.4.2.4 Red Neuronal Narx	65
2.4.3 Funcionamiento de una Red Neuronal Artificial (ANN)	66
2.4.4 Arquitectura de una red neuronal.....	67
2.4.4.1 Elementos básicos de una red neuronal.	68
2.4.5 Aprendizaje de las Redes Neuronales Artificiales.....	70
2.4.5.1 Paradigma de aprendizaje	70
2.4.5.2 Reglas de aprendizaje	71
2.4.5.3 Algoritmo de aprendizaje	71
2.4.6 Ventajas de las redes neuronales.....	71
2.4.6.1 Aprendizaje Adaptativo.	71

2.4.6.2 Auto-organización.	71
2.4.6.3 Tolerancia a fallos.	71
2.4.6.4 Operación en tiempo real.	72
2.4.6.5 Fácil inserción dentro de la tecnología existente.	72
2.4.7 Desventajas del uso de las redes neuronales.	72
2.4.7.1 Diseño y entrenamiento	72
2.4.7.2 Tiempo de aprendizajes.	72
2.4.7.3 Cantidad de datos requeridos	72
2.4.8 Estructura de las redes neuronales.	73
2.4.8.1 Redes mono capa.	73
2.4.8.2 Redes multicapa	73
2.4.8.3 Conexión entre neuronas.	74
2.4.8.4 Redes de propagación hacia atrás (backpropagation).	75
2.4.9 Aplicaciones de las redes neuronales.	75
2.5 CASO BOMBAS CENTRIFUGAS DE DIESEL PRODUCTO.	76
2.5.1. Características del equipo de bombeo.	76
2.5.2 Sistemas de protección de las bombas de diesel producto.	78
2.5.3 Fallas presentadas en las bombas de diesel producto.	82
2.5.3.1 Fugas internas/externas de medio auxiliar y de proceso.	83
2.5.3.2 Vibración y ruido.	85
2.5.3.3 Sobre calentamiento en sistema de flushing y líquido barrera.	88
2.5.3.4 Desviación de parámetros.	89
2.5.3.5 Rotura del eje.	93
2.5.3.6 Parada inesperada.	94
2.5.4 Análisis de fallas.	94
3. ADQUISICIÓN DE DATOS.	97
3.1 ADQUISICIÓN AUTOMÁTICA.	97
3.2 ADQUISICIÓN MANUAL	97
3.3 ANÁLISIS DE MODOS DE FALLA	99
4. DESARROLLO DEL MODELO	101

4.1 ETAPAS DEL DESARROLLO DEL MODELO	102
4.1.1 Selección de variables de entrada y salida.	102
4.1.1.1 Variables de entrada.....	103
4.1.1.2 Variables de salida.....	104
4.1.2 Adquisición, selección y normalización de datos.	104
4.1.3 Normalización de datos.....	104
4.1.3.1 Análisis de componentes principales (PCA).	105
4.1.3.2 Árbol de decisión (Decisión tres).	107
4.1.4 Selección de la estructura de la red.....	109
4.1.4.1. Perceptron multicapa	110
4.1.5 Entrenamiento y pruebas	111
4.1.5.1 Extracción de características	112
4.1.5.2 Análisis de Principales Componentes.....	113
4.1.5.3 Diseño de red neuronal Multicapas de tipo perceptron	118
4.1.5.4 Validación de resultados con conjunto de pruebas que nunca fueron usados para entrenar y se usan para validar	128
5. PLANES DE GESTIÓN.....	131
5.1 FALLA DE SELLO MECÁNICO	131
5.1.1 Ajuste de presión de líquido barrera	132
5.1.2 Ajuste de presión de N2 en la vejiga.....	132
5.1.3 Cambio de líquido barrera.....	133
5.1.4 Reparación de sello mecánico	134
5.2 FALLA DE ENFRIADORES	135
5.2.1 Retrolavado de enfriadores.....	135
5.2.2 Limpieza mecánica de enfriadores	136
5.2.3 Prueba hidrostática	137
5.2.4 Cambio del serpentín del enfriador	137
5.3 FALLA DE RODAMIENTOS	138
5.3.1 Monitoreo de vibraciones.....	139
5.3.2 Termografías.....	140

5.3.3 Análisis / Cambio de aceites lubricantes.....	141
5.3.4 Alineación de conjunto motor bomba.....	141
5.3.5 Cambio del eje.	142
5.3.6 Cambio de rodamientos.....	142
5.4 FALLA POR PARADA INESPERADA	143
5.4.1 Pruebas eléctricas	144
5.4.2 Mantenimiento general del motor.....	145
6. CONCLUSIONES	146
BIBLIOGRAFÍA.....	149
ANEXOS.....	152

LISTA DE FIGURAS

	Pág.
Figura 1. Consumo nacional de Diésel Hidrotratado.....	21
Figura 2. Reglamentación Nacional de Diésel Hidrotratado.	22
Figura 3. Bombas de Diésel Hidrotratado.	22
Figura 4. Modos de falla en Bombas de Diésel Hidrotratado.	23
Figura 5. Costos de mantenimiento en Bombas de Diésel Hidrotratado.....	23
Figura 6. MTBF en Bombas de Diésel Hidrotratado.	25
Figura 7. Logos en la historia de Ecopetrol S.A.....	28
Figura 8. Empresas Grupo Empresarial ECOPETROL S.A.....	29
Figura 9. Área de Influencia Operaciones Ecopetrol S.A.....	30
Figura 10. Infraestructura Ecopetrol S.A.....	30
Figura 11. Catálogo de Productos Ecopetrol S.A.....	31
Figura 12. Organigrama Ecopetrol S.A.....	32
Figura 13. Organigrama Vicepresidencia Ejecutiva Downstream Ecopetrol S.A ...	33
Figura 14. Organigrama Refinería Barrancabermeja Ecopetrol S.....	34
Figura 15. Localización Refinería Barrancabermeja Ecopetrol S.A	35
Figura 16. Balance másico de la Unidad de Hidrotratamiento de Diésel.	37
Figura 17. Gráfico de proceso de Diésel de la Unidad de Hidrotratamiento de Diésel.....	38
Figura 18. Bomba de Diesel producto.....	39
Figura 19. Curva P-F.	43
Figura 20. Curva de la Bañera.	45
Figura 21. Relación entre Confiabilidad, Disponibilidad y Mantenibilidad.	48
Figura 22. Modelos de detección y diagnóstico de fallas.....	49
Figura 23. Diagrama esquemático sistemas basados en caos.....	51
Figura 24. Modelo matemático.....	53

Figura 25. Red neuronal biológica.	59
Figura 26. Tipos de redes Neuronales.	63
Figura 27. Red neuronal Feedforward.	64
Figura 28. Red neuronal basada en retardos de tiempo.	65
Figura 29. Red neuronal NARX.	65
Figura 30. Modelo simplificado de la Neurona.	67
Figura 31. Ejemplo de una red neuronal totalmente conectada.	68
Figura 32. Funciones de activación de redes neuronales.	69
Figura 33. Ventajas y desventajas de la Redes neuronales.	73
Figura 34. Redes Multicapa.	74
Figura 35. Bomba Tipo BBS.	77
Figura 36. Bomba diésel producto de Diesel.	77
Figura 37. Válvulas de corte sistema de corte.	79
Figura 38. Sistema de diluvio bombas de diesel producto.	79
Figura 39. Plan de sellado 53B.	80
Figura 40. Sistema de sello con plan 21.	81
Figura 41. Sistema de sellado plan 21/53B.	81
Figura 42. Sistema DCS bombas de diesel producto.	82
Figura 43. Sistema de monitoreo de Vibraciones bombas de diesel producto.	82
Figura 44. Evidencias de falla en sistemas de sellado.	84
Figura 45. Proceso de mantenimiento de una bomba de diesel producto.	85
Figura 46. Cambio de rodamientos de una bomba de diesel producto.	85
Figura 47. Partículas en la succión de una bomba de diesel producto.	86
Figura 48. Espectro de vibración de una bomba de diesel producto.	87
Figura 49. Lubricación por salpique.	87
Figura 50. Enfriador de sistemas de sello de una bomba de diesel producto.	89
Figura 51. Límites de operación variables de proceso.	90
Figura 52. Datos de diseño de NPSHr a la succión de la bomba.	91
Figura 53. Efectos de Operar bombas centrifugas por fuera de la zona dulce.	92
Figura 54. Falla de eje de la bomba.	93

Figura 55. Falla de eje de la bomba.....	95
Figura 56. Análisis causa efecto	96
Figura 57. Pasos para el desarrollo del modelo.....	102
Figura 58. Ejemplo de Análisis de componentes principales.	106
Figura 59. Estructura de un árbol de decisión.....	107
Figura 60. Árbol de decisión en Mantenimiento.....	109
Figura 61. Red neuronal Feedforward.	110
Figura 62. Distribución de todos los Datos de Falla en las Bombas.	112
Figura 63. Análisis de Principales Componentes.....	113
Figura 64. Principales componentes.....	114
Figura 65. Comportamiento de las características.....	115
Figura 66. Composición particular PCA de cada modo de falla.....	116
Figura 67. Extracción de las características reducidas y la clasificación realizada por PCA	117
Figura 68. Principales componentes en el espacio tridimensional.....	118
Figura 69. Diseño de red neuronal Multicapas de tipo perceptron.....	120
Figura 70. Desempeño de la red para clasificar correctamente los modos de falla	122
Figura 71. Matriz de confusión.....	123
Figura 72. Datos de red neuronal.	124
Figura 73. Análisis de datos.....	125
Figura 74. Análisis de datos de la red neuronal.....	126
Figura 75. Análisis de datos de entrenamiento de la red	127
Figura 76. Validación de resultados.....	128
Figura 77. Validación de resultados.....	129
Figura 78. Validación de resultados.....	130
Figura 79. Ajuste de presión de líquido barrera.	132
Figura 80. Ajuste de presión de N2 en acumulador de sistema de sello.	133
Figura 81. Cambio de líquido barrera.	134
Figura 82. Reparación de sello mecánico.....	135

Figura 83. Retrolavado de enfriadores.....	136
Figura 84. Limpieza mecánica de enfriadores.	137
Figura 85. Prueba hidrostática a serpentín.	137
Figura 86. Plano de diseño para construcción de serpentín del enfriador.	138
Figura 87. Monitoreo de vibraciones.....	140
Figura 88. Termografía a rodamientos.....	140
Figura 89. Revisión de aceite de lubricación.	141
Figura 90. Análisis de laboratorio de aceite de lubricación.	141
Figura 91. Alineación conjunto motor bomba.....	142
Figura 92. Fabricación eje bomba centrifuga.	142
Figura 93. Cambio de rodamientos bomba centrifuga.	143
Figura 94. Pruebas eléctricas al motor.	145
Figura 95. Actividades de mantenimiento general del motor.	145

LISTA DE TABLAS

	Pág.
Tabla 1. Porcentaje de Modos de falla presentados en los equipos.	26
Tabla 2. Cantidad de Modos de falla presentados en los equipos (tiempo de análisis 3 años).	83
Tabla 3. Categorización de fallas.	99
Tabla 4. Análisis de falla en componentes.	100
Tabla 5. Variables de entrada para la red neuronal	103
Tabla 6. Datos de entrenamiento de la red neuronal.	120
Tabla 7. Plan de gestión de Mantenimiento para falla de sistema de sellos mecánicos.	131
Tabla 8. Valores de ajuste de presión de sistema de sellos.	133
Tabla 9. Plan de gestión de Mantenimiento para falla de Enfriadores de sistema de sellos mecánicos.	135
Tabla 10. Plan de gestión de Mantenimiento para falla de rodamientos, eje e impulsor.	139
Tabla 11. Plan de gestión de Mantenimiento para falla de parada inesperada. ..	144

LISTA DE ANEXOS

	Pág.
Anexo A. Datasheet Bomba de Diésel Producto.....	152
Anexo B. Hoja de seguridad Diésel.	153
Anexo C. Datos Modo de Operación Optimo (sin fallas).....	154
Anexo D. Datos Modo de Operación Optimo (sin fallas).....	155
Anexo E. Datos Modo de Operación Optimo (sin fallas).....	156
Anexo F. Datos Modo de Falla Sello Mecánico.	157
Anexo G. Datos Modo de Falla de Rodamientos.....	158
Anexo H. Datos Modo de Falla de Enfriadores.	159
Anexo I. Datos Modo de Falla Parada inesperada.....	160
Anexo J. Planes de gestión.	161

RESUMEN

TÍTULO: MODELO DE DETECCIÓN Y DIAGNOSTICO BASADO EN CONFIABILIDAD PARA LA DETECCIÓN DE FALLAS EN LAS BOMBAS DE DIESEL PRODUCTO HIDROTRATADO DE LAS UNIDADES DE HIDROTRATAMIENTO DE COMBUSTIBLES DE ECOPETROL EN LA GRB*.

AUTORES: FREDY E. MALDONADO FLÓREZ**.

PALABRAS CLAVES: CONFIABILIDAD, DISPONIBILIDAD, MANTENIBILIDAD, BOMBAS CENTRIFUGAS, MANTENIMIENTO PREDICTIVO, REDES NEURONALES, DETECCION Y DIAGNOSTICO DE FALLAS.

DESCRIPCIÓN:

La finalidad del presente trabajo, es proponer un Modelo de detección y diagnóstico de fallas en los diferentes componentes de bombas centrifugas, con el fin de mejorar su confiabilidad y disponibilidad, dada la importancia que tienen estos equipos en el proceso de hidrotratamiento de combustibles en nuestras unidades de proceso y su impacto en la economía del país.

La razón principal del desarrollo de este trabajo es la de mejorar las condiciones actuales en donde los equipos en estudio presentan alta tasa de falla y altos costos de mantenimiento, afectando los indicadores de confiabilidad y disponibilidad.

Para el desarrollo del trabajo se adquirirá la información necesaria y disponible que permita la toma acertada de decisiones. Con esta información se revisaran los modelos disponibles de redes neuronales y se elegirá la más adecuada para nuestro objetivo y poder realizar su entrenamiento con la información disponible. En este proceso, se tienen en cuenta los diferentes modos de falla presentados en este tipo de activos y de acuerdo a los datos proporcionados por el modelo, se plantearan diferentes acciones para evitar o minimizar su ocurrencia.

Por medio del uso de redes neuronales se quiere mejorar la confiabilidad, disponibilidad y mantenibilidad de los equipos en estudio, ya que este método es muy efectivo a la hora de la predicción, detección y diagnóstico de fallas.

Con el modelo propuesto esperamos validar el uso de las redes neuronales para la detección de fallas y poder aplicar este tipo de herramientas en otros tipos de equipos.

* Trabajo de grado

** Facultad de Ingenierías Físico-mecánicas, Maestría en Gerencia de Mantenimiento. Director: Carlos Borrás Pinilla PhD. D. Ingeniero Mecánico

SUMMARY

TÍTULO: DETECTION AND DIAGNOSTIC MODEL BASED ON RELIABILITY FOR THE DETECTION OF FAULTS IN THE DIESEL PUMPS HYDROTREATED PRODUCT OF THE ECOPETROL FUEL HYDROTRAPMENT UNITS IN THE GRB*.

AUTHOR: FREDY E. MALDONADO FLÓREZ**.

KEYWORDS: RELIABILITY, AVAILABILITY, MAINTENANCE, CENTRIFUGAL PUMPS, PREDICTIVE MAINTENANCE, NEURONAL NETWORKS, DETECTION AND FAULT DIAGNOSIS.

DESCRIPCIÓN:

The purpose of this work is to propose a model for the detection and diagnosis of faults in the different components of centrifugal pumps, in order to improve their reliability and availability, given the importance of this equipment in the process of hydrotreating fuels in our process units and their impact on the country's economy.

The main reason for the development of this work is to improve the current conditions where the equipment under study has a high failure rate and high maintenance costs, affecting the reliability and availability indicators.

For the development of the work, the necessary and available information will be acquired that allows the correct decision making. With this information we will review the available models of neural networks and choose the most appropriate for our objective and be able to carry out their training with the available information. In this process, the different failure modes presented in this type of assets are taken into account and according to the data provided by the model, different actions will be considered to avoid or minimize their occurrence.

Through the use of neural networks we want to improve the reliability, availability and maintainability of the equipment under study, since this method is very effective when it comes to predicting, detecting and diagnosing faults.

With the proposed model, we hope to validate the use of neural networks for the detection of faults and to be able to apply this type of tools in other types of equipment.

* Work of degree

** Faculty of Engineering Physical and Mechanics, Mastery in Maintenance Management. Director: Carlos Borrás Pinilla PhD. Mechanical Engineering

INTRODUCCIÓN

El funcionamiento de los procesos industriales ha cambiado drásticamente en los últimos tiempos, haciéndose día a día más exigente. La automatización de estos procesos ha generado un aumento de la productividad, obligando a la industria a adaptarse a las nuevas demandas del mercado y a aumentar su competitividad.

Para esto, ha sido necesario desarrollar nuevas técnicas, métodos y herramientas que permitan maximizar la eficiencia de los procesos, desarrollando modelos que prevengan fallas en los equipos mediante la detección y diagnóstico de las mismas.

El campo de utilización de dichos modelos es muy amplio y se destacan aplicaciones en control, supervisión, predicción, simulación y optimización de los procesos.


En la actualidad y cada vez más, el trabajo de un Ingeniero consiste en la construcción de modelos matemáticos de los procesos, y para ello es imprescindible conocer su comportamiento dinámico, principalmente de las partes más críticas. Estos modelos deben ser bastante precisos para poder expresar las desviaciones resultantes de fallas presentadas.

1. GENERALIDADES DEL PROYECTO

1.1 PLANTEAMIENTO DEL PROBLEMA


Las unidades de hidrotratamiento de combustibles de la Gerencia Refinería Barrancabermeja (GRB) propiedad de Ecopetrol S.A., son las encargadas de producir la gasolina hidrotratada y el diésel hidrotratado como productos finales del Complejo, los cuales suplen cerca del 80% de la demanda nacional en combustibles. El restante volumen requerido para el mercado nacional es importado al país por medio de una red de poliductos que lo llevan desde la costa hasta los centros de distribución (ver figura 1).

Figura 1. Consumo nacional de Diésel Hidrotratado



Actualmente la regulación ambiental de Colombia, en el caso del diésel, exige que este llegue a los usuarios finales (en especial transporte masivo) con un contenido máximo de 50ppm (%v/v) de azufre, lo cual busca reducir la contaminación del aire, en especial en grandes ciudades como Bogotá, Medellín, entre otras (ver figura 2).

Figura 2. Reglamentación Nacional de Diésel Hidrotratado.



Fuente: MINMINAS [en línea] disponible en: www.minminas.gov.co


Dentro de los equipos más críticos de la unidad de hidrotratamiento de diésel, se encuentran las bombas de diésel producto (figura 3), las cuales se encargan de enviar el diésel hidrotatado producto con bajo contenido de azufre hacia los tanques de almacenamiento finales, para ser mezclado con otras corrientes y ser distribuidos a lo largo y ancho del país por medio de poliductos.

Figura 3. Bombas de Diésel Hidrotratado.



Estos equipos han presentado constantes fallas y con diferentes modos de falla, ocasionando paradas no programadas en la unidad y por ende altos costos de lucro cesante y altos costos de reparación de los equipos (figura 4), los cuales han sido mucho mayores a los planeados anualmente, convirtiéndose en equipos críticos y malos actores.

Figura 4. Modos de falla en Bombas de Diésel Hidrotratado.



Teniendo en cuenta lo anterior es necesario crear una estrategia que minimice estos fallos y permita que la Unidad sea más confiable en su operación, optimizando sus costos de mantenimiento (figura 5).

Figura 5. Costos de mantenimiento en Bombas de Diésel Hidrotratado.



1.2 HIPÓTESIS

De acuerdo al problema presentado, planteamos la siguiente Hipótesis para desarrollar este proyecto:

¿Es posible mediante el uso de Redes Neuronales desarrollar un modelo de gestión y mantenimiento que me ayude a la detección de fallas en bombas centrífugas?

1.3 OBJETIVOS

1.3.1 Objetivo general. Desarrollar un modelo de gestión de mantenimiento basado en confiabilidad, usando redes neuronales para la detección de fallas en las bombas de diésel producto hidrotratado de las unidades de HDT de Ecopetrol S.A.

1.3.2 Objetivos específicos:

- Clasificar los modos de falla presentados en los equipos en estudio.
- Seleccionar las arquitecturas de redes neuronales aplicables a la detección y diagnóstico de fallas y la aplicación de la mejor opción para este caso.
- Utilizar Matlab como software de simulación, para elaborar el modelo de gestión de mantenimiento.
- Diseñar un modelo de gestión de mantenimiento basado en confiabilidad usando Redes Neuronales para la detección y diagnóstico de fallas en los equipos en estudio.


1.4 JUSTIFICACIÓN

Las unidades de hidrotratamiento de combustibles de la GRB, son las unidades operativas más críticas dentro de la operación de la Refinería de Barrancabermeja de Ecopetrol S.A., ya que se requiere su operación continua y confiable, con el fin de entregar al mercado del país combustibles con bajo contenido de azufre como diésel, gasolina y jet, para cumplir con la demanda nacional de estos productos, los cuales son el motor de la economía nacional.

A pesar de ser unidades que solo llevan 9 años de operación, se evidencian varias oportunidades de mejora en sus procesos operativos, procesos de mantenimiento y la gestión de repuestos e insumos, los cuales buscamos mejorar con esta estrategia, para mejorar la confiabilidad de los equipos en estudio.

Por esto se requiere diseñar una estrategia que asegure la disponibilidad operativa de los equipos en estudio y así mismo de las Unidades, logrando optimizar al máximo la confiabilidad de sus equipos críticos, reduciendo al mínimo las fallas, optimizando los costos de mantenimiento, reduciendo los reprocesos de mantenimiento y obteniendo mayores rendimientos de sus productos (figura 6).

Figura 6. MTBF en Bombas de Diésel Hidrotratado.



Con este trabajo queremos determinar los factores que más generen fallas en estos equipos críticos y en base a esto, establecer las tareas que logren prevenir las fallas que afectan a estos equipos.

Analizando los modos de falla presentados en estos equipos (ver tabla 1), sus condiciones de operación y la estrategia de mantenimiento actual, se establecerá por medio de herramientas como simulaciones o modelos la mejora alternativa para optimizar su operación.

Tabla 1. Porcentaje de Modos de falla presentados en los equipos.

MODO DE FALLA	% DE LAS FALLAS
Falla de sellos (fuga externa e interna)	38,9
Sobrecalentamiento (sistema de sello y flushing)	16,7
Desviación de parámetros (temperatura y presión)	11,1
Taponamiento/Restringido (enfriadores sello)	11,1
Vibración	5,6
Ruido	5,6
Rotura (eje)	5,6
Parada inesperada	5,6

Al final, lo que queremos lograr, es que las unidades y sus equipos sean más confiables dentro de la Refinería, para cumplir los objetivos establecidos y no afectar los planes de producción.

De acuerdo con los resultados obtenidos en este plan aplicado a los equipos estudiados, se busca ser aplicado en otros equipos críticos de otras unidades que presenten las mismas oportunidades.

El uso de nuevas herramientas de diagnóstico y predicción permitirá avanzar en el mejoramiento de los procesos, ya que estas tecnologías son ampliamente usadas en diferentes áreas de estudio, obteniendo buenos resultados para los procesos.

Con todo lo anterior, podremos poner en práctica varios de los temas contenidos dentro de la maestría en Gerencia de Mantenimiento con el fin de poder desarrollarnos profesionalmente y poner a disposición de la Industria nuestros conocimientos.

1.5 CONTEXTO

1.5.1 Descripción de la Empresa. La reversión al Estado Colombiano de la concesión De Mares, el 25 de agosto de 1951, dio origen a la Empresa Colombiana de Petróleos Ecopetrol S.A.

Ecopetrol S.A. es una sociedad de economía Mixta, de carácter comercial, organizada bajo la forma de sociedad anónima, del orden nacional, vinculada al Ministerio de Minas y Energía. Ecopetrol S.A. es la principal empresa petrolera de Colombia, está dedicada a explorar, producir, transportar, refinar y comercializar hidrocarburos derivados como combustibles, materias primas y petroquímicos. (ver figura 7)

Figura 7. Logos en la historia de Ecopetrol S.A



Fuente: ECOPETROL Contenido [en línea] disponible en: www.ecopetrol.com.co/contenido.aspx.

A partir de 2003, Ecopetrol S.A. inició una era en la que, con mayor autonomía, ha acelerado sus actividades de exploración, su capacidad de obtener resultados con visión empresarial y comercial y el interés por mejorar su competitividad en el mercado petrolero mundial.

Actualmente, Ecopetrol S.A. es la empresa más grande del país con una utilidad neta de \$15,4 billones registrada en 2017 y la principal compañía petrolera en Colombia. Por su tamaño, pertenece al grupo de las 40 petroleras más grandes del mundo y es una de las cuatro principales de Latinoamérica.

1.5.2 Grupo Empresarial Ecopetrol. Ecopetrol S.A. es hoy en día un Grupo empresarial, en el cual se tiene la participación total y parcial de un gran número de Empresas del sector de Petróleo y gas, con el fin de diversificar sus portafolios y de esta manera aprovechar los diferentes recursos con los que se cuenta.

El G.E Ecopetrol, participa en forma de Filial, Subsidiaria y con Participación accionaria en las siguientes empresas (ver figura 8):

Figura 8. Empresas Grupo Empresarial ECOPETROL S.A.



Fuente: ECOPETROL Contenidos [en línea] disponible en: www.ecopetrol.com.co/contenido.aspx

1.5.3 Área de influencia de las Operaciones de Ecopetrol S.A. Ecopetrol mantiene operaciones de exploración, producción, transporte y refinación de hidrocarburos en diferentes lugares a lo largo y ancho del territorio nacional e internacionalmente en países como México, Brasil, Perú entre otros. (Ver figura 9)

Figura 9. Área de Influencia Operaciones Ecopetrol S.A



Fuente: ECOPETROL Contenido [en línea] disponible en:
www.ecopetrol.com.co/contenido.aspx

Ecopetrol posee la siguiente infraestructura en Colombia (ver figura 10):

Figura 10. Infraestructura Ecopetrol S.A



Fuente: ECOPETROL Contenido [en línea] disponible en:
www.ecopetrol.com.co/contenido.aspx

1.5.4 Portafolio de servicios y productos de ECOPETROL S.A. Ecopetrol ofrece un amplio portafolio de productos entre los cuales se destacan los combustibles, petroquímicos, crudo y gas natural. (ver figura 11)

Figura 11. Catálogo de Productos Ecopetrol S.A.



Fuente: ECOPETROL Contenido [en línea] disponible en: www.ecopetrol.com.co/contenido.aspx

1.5.5 Estructura organizacional de ECOPETROL S.A. La estructura organizacional de Ecopetrol S.A. está encabezada por una Junta Directiva, en la cual la nación tiene amplia participación con funcionarios del gobierno, y en donde también la tienen los Accionistas minoritarios y los Departamentos productores de hidrocarburos. (ver figura 12)

Figura 12. Organigrama Ecopetrol S.A.




Fuente: ECOPETROL Contenido [en línea] disponible en: www.ecopetrol.com.co/contenido.aspx

A la junta le precede la Presidencia del Grupo empresarial y de allí se desprenden las Vicepresidencias de las diferentes áreas de operación de la empresa.

La Gerencia Refinería Barrancabermeja, pertenece a la Vicepresidencia de Refinación y Procesos Industriales, que a su vez, depende de la Vicepresidencia ejecutiva del Downstream. (Ver figura 13)


Figura 13. Organigrama Vicepresidencia Ejecutiva Downstream Ecopetrol S.A



Fuente: ECOPETROL Contenido [en línea] disponible en: www.ecopetrol.com.co/contenido.aspx

La Gerencia Refinería Barrancabermeja, se encuentra dividida en las áreas de gestión Integral del riesgo, gerencia Técnica, el Departamento de Programación de Producción y la Gerencia de Producción, a la cual pertenecen las áreas operativas y de producción, entre ellas las Unidades de Hidrotratamiento de combustibles HDT, pertenecientes al Departamento de Refinación de Crudos. (ver figura 14)

Figura 14. Organigrama Refinería Barrancabermeja Ecopetrol S.



Fuente: ECOPETROL Contenido [en línea] disponible en: www.ecopetrol.com.co/contenido.aspx

1.5.6 Localización Refinería Barrancabermeja Ecopetrol S.A. En la Ciudad de Barrancabermeja (Departamento de Santander) está localizada la Refinería de Petróleo más grande de Colombia, (ver figura 15) la cual refina aproximadamente 252.000 barriles diarios de Crudo; además abastece cerca del 80% de productos refinados y el 90% de los productos petroquímicos que demanda el país.

Figura 15. Localización Refinería Barrancabermeja Ecopetrol S.A



Fuente: ECOPETROL Contenido [en línea] disponible en: www.ecopetrol.com.co/contenido.aspx

Estas instalaciones ocupan 206 hectáreas, cuenta con más de 50 plantas de procesamiento y se autoabastece de servicios industriales como vapor, electricidad, agua industrial, por lo cual este complejo es reconocido entre los más grandes y antiguos de Latinoamérica.

La Refinería de Barrancabermeja es el principal centro de refinación y Petroquímica, ubicada al interior del país, por lo cual lo hace pieza estratégica en la infraestructura energética del país, elemental para el funcionamiento de su economía.

En 2007 la Refinería tenía una capacidad instalada de 250.000 barriles e inicia la construcción de las llamada Platas ambientales (Planta de Generación de Hidrógeno, Planta de Hidrotratamiento de Combustibles Nafta y ACPM, Planta de Tratamientos de Amina, Azufre y Aguas Agrias) con el fin de cumplir la demanda de

combustibles más limpios para el país, de acuerdo a la regulación ambiental de la cual exige que este llegue a los usuarios finales con un contenido máximo de 50 ppm (%v/v) de azufre en el caso del Diésel y 300 ppm (%v/v) de azufre en el caso de la Gasolina, lo cual busca reducir la contaminación del aire, en especial en grandes ciudades como Bogotá, Medellín, entre otras.


1.5.7 Unidad de Hidrotratamiento de Diésel de la Refinería Barrancabermeja de ECOPETROL S.A. La Unidad de Hidrotratamiento de Diésel está diseñada para tratar una mezcla de Diésel virgen de alto contenido de azufre (83%), proveniente de las unidades de destilación atmosférica y aceite liviano de ciclo de cracking (17%), de las unidades de craqueo catalítico (FCC), para producir Diésel de ultra bajo contenido de azufre (ULSD), con contenidos de azufre entre 5 y 25 ppm (w) en los diferentes productos de la unidad.

Actualmente la Unidad procesa una carga máxima de 66.000 BPD, equivalente a un 80% de la demanda nacional. (ver figura 16)

La unidad habilita a ECOPETROL S.A. para producir componentes que irán al sistema de blending de Diésel y así poder cumplir con la resolución 1180 del Gobierno Colombiano, para combustibles más limpios para el mercado Colombiano.

El Diésel producto también es separado en corrientes de Diésel liviano con un punto final de 360°C y Diésel pesado con punto final de 390°C; que permitirán en el blending de Diésel, cumplir con las demandas de Diésel extra y Diésel regular.

Figura 16. Balance másico de la Unidad de Hidrotratamiento de Diésel.




Fuente: ECOPETROL Contenido [en línea] disponible en:
www.ecopetrol.com.co/contenido.aspx

El producto final de esta Unidad es el Diésel de bajo azufre (20 PPM), el cual es enviado a Almacenamiento para su posterior distribución a nivel nacional.

Para poder realizar el envío de este producto hacia el área de almacenamiento se hace por medio de dos bombas centrífugas de alta potencia, conocidas bajo el tag de SP 4704 A/B. (ver figura 17)

Figura 17. Gráfico de proceso de Diésel de la Unidad de Hidrotratamiento de Diésel.



Fuente: ECOPETROL Contenido [en línea] disponible en: www.ecopetrol.com.co/contenido.aspx

Precisamente estas dos bombas son las que se van a analizar en este proyecto, debido a que presentan varias oportunidades. (ver figura 18)

Figura 18. Bomba de Diesel producto



Fuente: ECOPETROL Contenido [en línea] disponible en:
www.ecopetrol.com.co/contenido.aspx

1.6 METODOLOGÍA

La metodología para desarrollar el proyecto consiste en los siguientes pasos:

- a) Investigar sobre el estado del arte en los temas de confiabilidad, mantenibilidad y modelos de gestión de mantenimiento que me permitan la toma de decisiones para detectar y evitar fallas en los equipos, con el fin de reducir los costos e impactos a la producción.
- b) Analizar los modos de falla que se presentan o se pueden llegar a presentar en los equipos analizados, para poder establecer una base adecuada para el diseño del modelo propuesto.
- c) Revisar y adquirir la información necesaria y disponible para los diferentes análisis, incluyendo datos reales que me permitan diseñar el modelo de forma adecuada.

d) Revisar los modelos supervisados o Redes Neuronales disponibles para la elaboración del modelo propuesto.

e) Seleccionar el modelo más adecuado para la Detección de fallas en los equipos analizados partiendo de los datos base obtenidos, con el cual se pueda realizar la toma de decisiones para establecer una estrategia de mantenimiento más adecuada, a fin de evitar fallas.

f) Evaluar el modelo aplicado con los resultados obtenidos mediante la validación de estos con la estrategia a establecer.

2. ANÁLISIS DE LA LITERATURA RECOPIADA

2.1 MARCO TEÓRICO

2.1.1 Mantenimiento El mantenimiento puede ser definido como el conjunto de acciones destinadas a mantener o reacondicionar un componente, equipo o sistema, en un estado en el cual sus funciones pueden ser cumplidas. Entendiendo como función cualquier actividad que un componente, equipo o sistema desempeña, bajo el punto de vista operacional. ¹

Las palabras confiabilidad, disponibilidad y mantenibilidad, forman parte de la cotidianidad del mantenimiento. Si se analiza la definición moderna de mantenimiento, se verifica que la misión de este es “garantizar” la disponibilidad de la función de los equipos e instalaciones, de tal modo que permita atender a un proceso de producción o de servicio con calidad, confiabilidad, seguridad, preservación del medio ambiente y costo adecuado. ²

La confiabilidad, disponibilidad y mantenibilidad son muy importantes en la actualidad. Históricamente, la confiabilidad fue aplicada por primera vez a equipos eléctricos y electrónicos en control de calidad de fabricantes en los años 1940 y luego fue extendida a otras áreas como la militar, aeroespacial y nuclear, entre otra.³

2.1.2 Confiabilidad La confiabilidad puede ser definida como la “confianza” que se tiene de que un componente, equipo o sistema desempeñe su función básica,

¹ KARDEK, A., NASCIF, J. Mantenimiento, Función Estratégica, CIP Brasil, Rio de Janeiro, 2002

² Ibíd.

³ ROLF Iserman. Fault diagnostica systems. Springer Verlag London, 2006.

durante un período de tiempo preestablecido, bajo condiciones estándares de operación.

Esta puede ser expresada a través de la expresión:

$$R(t) = e^{-\lambda t} \quad (1)$$

Donde:

R (t): Confiabilidad de un equipo en un tiempo t dado

e: constante Neperiana ($e=2.303$)

λ : Tasa de fallas (número total de fallas por período de operación)

t: tiempo ⁴

2.1.3 Falla Se define como la desviación no permitida de al menos una característica propia de una variable del sistema.

La figura 19 muestra este proceso. Se la denomina curva P-F porque muestra cómo una falla comienza y prosigue el deterioro hasta un punto en el cual puede ser detectado (el punto de falla potencial "P"). A partir de allí, si no se detecta y no se toman las acciones adecuadas, continúa el deterioro -a veces a un ritmo acelerado - hasta alcanzar el punto "F" de falla funcional. ⁵

4 LAFRAIA, J. R Manual de confiabilidad, Mantenabilidad e disponibilidad, Qualitymark Editora, 2001.

5 Gestión de activos físicos", Apuntes para el curso ME 5701, Departamento de Ingeniería Mecánica, Universidad de Chile.

Figura 19. Curva P-F.



Fuente: LIVING RELIABILITY [en línea] disponible en: <http://www.livingreliability.com>

2.1.4 Modo de falla Es una causa de falla o una posible manera en la que un sistema puede fallar.

Cuando un sistema o equipo tiene muchas formas posibles de fallar, tiene múltiples modos de falla. Mientras más complejo sea el sistema, más modos de falla tendrá.

Debido a que los diferentes modos de falla frecuentemente tienen diferentes distribuciones de fallas, por lo general lo mejor es agrupar los datos de fallas por modo de falla.

Comprender los modos de falla de un sistema o equipo es muy importante para mejorar la confiabilidad del sistema o instalación.

El análisis de modos de falla y efectos (FMEA) es la metodología utilizada para analizar las causas de las fallas y para entender su frecuencia e impacto. Cuando

se identifican modos de falla potencial y su impacto, puede poner en marcha las acciones y planes correctivos apropiados.⁶

2.1.5 Tasa de Falla λ La tasa de falla ($\lambda(t)$) se define como el número de fallas por unidad de tiempo. Considerando un grupo N de componentes o equipos, en un tiempo t se han producido un número total k de fallas. El tiempo acumulado T, bien dado por N.t y la tasa de falla se estima por:

$$\lambda = \frac{k}{T} = \frac{k}{N.t} \quad (2)$$

Donde:

N: número de componentes

T: tiempo en donde se han producido las fallas


k: número de fallas.

La tasa de falla de un sistema puede variar en el tiempo. La curva de la bañera de la Figura 20, describe la variación de la tasa de falla en componentes durante la vida útil.⁷

⁶ MINITAB What is a failure mode [en línea] disponible en: <https://support.minitab.com/es-mx/minitab/18/help-and-how-to/modeling-statistics/reliability/supporting-topics/basics/what-is-a-failure-mode/>

⁷ Gestión de activos físicos", Apuntes para el curso ME 5701, Departamento de Ingeniería Mecánica, Universidad de Chile.

Figura 20. Curva de la Bañera.



Fuente: LIVING RELIABILITY [en línea] disponible en:
<http://www.livingreliability.com>

2.1.6 Tiempo Medio entre Fallas MTTF Se define para un periodo determinado de tiempo en la vida de un componente como la razón entre el tiempo total acumulado y el número de fallas. Se calcula como la razón entre el tiempo total acumulado y el número de fallas.

$$MTTF = \frac{T}{k} \quad (3)$$

De donde se deduce la relación:

$$MTTF = \frac{1}{\lambda} \quad (4)$$

Donde λ es la tasa de falla.

2.1.7 Mantenibilidad. La mantenibilidad se puede definir como la expectativa que se tiene de que un equipo o sistema pueda ser colocado en condiciones de

operación dentro de un periodo de tiempo establecido, cuando la acción de mantenimiento es ejecutada de acuerdo con procedimientos prescritos. ⁸

De manera análoga a la confiabilidad, la mantenibilidad puede ser estimada con ayuda de la expresión:

$$M(t) = 1 - e^{-\mu t} \quad (5)$$

Donde:

M(t): es la función mantenibilidad, que representa la probabilidad de que la reparación comience en el tiempo $t=0$ y sea concluida satisfactoriamente en el tiempo t (probabilidad de duración de la reparación).

e: constante Neperiana ($e=2.303$)

μ : Tasa de reparaciones o número total de reparaciones efectuadas con relación al total de horas de reparación del equipo.

t: tiempo previsto de reparación MTTR

2.1.8 Disponibilidad Es la probabilidad de que el mismo se encuentre operando en óptimas condiciones en un instante de tiempo y bajo condiciones de trabajo normales.

Resulta sumamente conveniente hablar de disponibilidad porque da idea del rendimiento del sistema en términos de mantenimiento y, por lo tanto, de

⁸ MESA GRAJALES, Dairo H., ORTIZ SÁNCHEZ, Yesid, PINZÓN, Manuel, La confiabilidad, la disponibilidad y la mantenibilidad, disciplinas modernas aplicadas al mantenimiento. Scientia Et Technica [en línea] 2006, XII

organización empresarial con todas sus implicancias y consecuencias, aspectos que no son contemplados por la confiabilidad.

La disponibilidad no es una función del tiempo, pero sí de la confiabilidad y de la mantenibilidad a través de la relación

$$\frac{MTTF}{MTTR} \quad (6)$$

A medida que ésta disminuye, aumenta el efecto que la mantenibilidad tiene sobre la disponibilidad.

Como en el diseño de todo sistema existe siempre una relación económica óptima entre los dos factores, no es cuestión de aumentar exageradamente la confiabilidad si ello no mejora justificadamente la disponibilidad.

$$A_1 = \frac{MTTF}{MTTF + MTTR} \quad (7)$$


2.1.9 Relación entre Confiabilidad, Mantenibilidad y Disponibilidad. Para aumentar la producción en una planta, es indispensable que las tres disciplinas Confiabilidad, Disponibilidad y Mantenibilidad se relacionen entre sí (ver figura 21), de tal manera que:

Si se quiere aumentar la disponibilidad en una planta, sistema o equipo se debe:

- Aumentar la confiabilidad, expresada en el MTTF.
- Reducir el tiempo empleado en la reparación, expresado en MTTR.
- Aumentar el TMEF y reducir el MTTR simultáneamente.⁹

⁹ Ibíd.

Figura 21. Relación entre Confiabilidad, Disponibilidad y Mantenibilidad.



Fuente: SISTEMAS MANUFACTURA Sesión 22 [en línea] disponible en: www.sistemasmanufactura.files.wordpress.com/2011/05/sesion-22.pdf

2.2 DETECCIÓN Y DIAGNOSTICO DE FALLAS

Las fallas son acciones internas e impredecibles que ocurren en un sistema, generadas por el mal funcionamiento de uno o más componentes y que pueden llevar al mismo a un estado no deseado. Las fallas pueden ocurrir en diferentes tipos de sistemas. Las fallas en los sistemas mecánicos se pueden clasificar dentro de las fallas de mecanismos: distorsión (deformación), fatiga y fractura (fatiga cíclica y térmica), desgastes (abrasiva, adhesiva, cavitación) o corrosión (galvánica, química o biológica).¹⁰


La detección y diagnóstico de fallas consiste en la determinación del tipo de fallas con tantos detalles como sea posible.

Existen diversas tecnologías posibles para la detección y diagnóstico de fallas (ver figura 22):¹¹

¹⁰ ARANGUREN, Sandra. Metodologías y tecnologías de detección y diagnóstico de fallas aplicadas a procesos Industriales. Revista Colombiana de Tecnologías de Avanzada 2009.

¹¹ DÍAZ, Fabián. Detección de fallas en bombas usando SVM. Tesis de Maestría, Bucaramanga: Universidad Industrial de Santander. 2017 28 p.

Figura 22. Modelos de detección y diagnóstico de fallas



Fuente: DIAZ, Fabián. Detección de fallas en bombas usando SVM. Tesis de Maestría, Bucaramanga: Universidad Industrial de Santander. 2017 28 p.

Los métodos basados en modelos de detección de fallas, usan las relaciones entre varias variables medidas, para extraer información sobre posibles cambios causados por fallas. Estas relaciones son mayormente relaciones analíticas en forma de ecuaciones de modelo de procesos, pero también pueden presentarse en forma de reglas.

2.2.1 Sistemas expertos basados en Reglas. Tienen una amplia aplicación en tareas de diagnóstico donde se cuenta con buena experiencia, pero el conocimiento de condiciones físicas son de difícil consecución por temas de facilidad o costos. Un

sistema de detección basado en reglas puede ser desarrollado en múltiples pasos y después codificados como reglas. Cada regla describe la acción que deberá ser tomada si se observa un síntoma de una falla para un diagnóstico.

Emplea dos métodos de razonamiento para diagnosticar fallas. Primero parte de una hipótesis, un algoritmo de encadenamiento que hacia atrás recoge o verifica la evidencia que apoya la hipótesis, y si esta se comprueba, entonces la hipótesis se describe como el resultado del diagnóstico. El segundo método de encadenamiento hacia adelante, verifica las reglas para ver cuál coincide con la evidencia.

El proceso es simple, pero si más de una de las reglas coinciden, se pueden presentar conflictos y estas deben ser priorizadas. Las reglas con mayor prioridad se aplican primero para obtener conclusiones del diagnóstico.¹²

2.2.2 Sistemas Expertos Basados en caos. El Razonamiento con sistemas basados en caos significa usar viejas experiencias para comprender y resolver nuevos problemas. En él, quien razona recuerda una situación previa, similar a la actual y usa esto para resolver el nuevo problema.¹³


Soluciona problemas basándose en soluciones de problemas presentados en el pasado. La experiencia del comportamiento es esencial para construir un efectivo diagnostico basado en caos. Este sistema incluye un componente de aprendizaje que hace posible el diagnóstico. Este sistema basado en caos, consiste de una biblioteca que contiene características que describen el problema, los resultados, las soluciones, los métodos y una evaluación de la eficacia del sistema.¹¹

¹² DIAZ, Fabián. Detección de fallas en bombas usando SVM. Tesis de Maestría, Bucaramanga: Universidad Industrial de Santander. 2017 28 p.

¹³ MOYA, Jorge y otros. Utilización de Sistemas Basados en Reglas y en Casos para diseñar transmisiones por tornillo sinfín. Universidad Autónoma de Zacatecas y Universidad Central Cuba, Facultad de Ingeniería Mecánica, 2011

Un Sistema Basado en Casos típico consta de 3 partes principales: la Base de Casos, el Módulo de Recuperación y el Módulo de Adaptación (ver figura 23). Los casos son problemas resueltos y almacenados en la Base de Casos. Cuando hay un nuevo problema que resolver, éste es descrito para el Módulo de Recuperación, el cual realiza una búsqueda en la Base de Casos y encuentra problemas o casos similares. Estos problemas o casos similares resueltos son recuperados (soluciones similares) y enviados al Módulo de Adaptación, donde son analizados para construir una solución para el nuevo problema.

Figura 23. Diagrama esquemático sistemas basados en caos.



Fuente: MOYA, Jorge y otros. Utilización de Sistemas Basados en Reglas y en Casos para diseñar transmisiones por tornillo sinfín. Universidad Autónoma de Zacatecas y Universidad Central Cuba, Facultad de Ingeniería Mecánica, 2011

Su estructura tiene 4 pasos:

Recordar: Toma en cuenta casos similares.

Reutilizar: Encuentra la diferencia entre el caos del pasado y presenta y transfiere o modifica la solución aceptándola a una nueva, con el fin de resolver el problema.

Revisar: si la solución es la apropiada o exitosa o no.

Retener: Incorpora esta nueva solución al conocimiento existente.

2.2.3 Sistemas basados en Razonamiento. En estos métodos encontramos dos subtipos. Los que hacen uso de modelos para la generación explícita de residuos a modo de redundancia y aquellos que hacen uso de modelos cualitativos para expresar causa-efecto. Este modelo es usualmente desarrollado con base en el entendimiento previo de las leyes físicas que gobiernan el sistema. En los modelos contruidos para la generación de residuos este entendimiento es expresado en términos de relaciones matemáticas entre las entradas y salidas del sistema.¹⁴

2.2.4 Sistemas de Aprendizaje Se derivan directamente de las rutinas de monitoreo de operación del sistema, basados en la suposición de que las características estadísticas de los datos tanto operativos, como de confiabilidad (vibración, presión, temperatura, estado del aceite, ruido, potencia, entre otros), son estables a menos que un evento de mal funcionamiento suceda en el sistema. Las variaciones de causa común son del todo debido a las incertidumbres y el ruido aleatorio, mientras que las variaciones de causa especial, son debido a fallas.

La importancia de las técnicas basadas en datos, es la capacidad de convertir datos de ruidos de alto valor, en información de menor dimensión para detección y diagnóstico, sin embargo el principal inconveniente es que su eficacia depende enormemente de la cantidad y calidad de la información o datos obtenidos del sistema.

2.2.4.1 Diagnostico y detección con modelos de análisis de señales. Estos modelos usan herramientas como análisis de componentes principales (PCA) funciones de correlación, análisis de Fourier (FFT), análisis de wavelet, por nombrar algunos de los más importantes. Estos modelos son conocidos como modelos de

¹⁴ DIAZ, Fabián. Detección de fallas en bombas usando SVM. Tesis de Maestría, Bucaramanga: Universidad Industrial de Santander. 2017 28 p


caja blanca, por poseer características como cambios en los umbrales, variación de amplitudes, frecuencias de los componentes modelos de ecuaciones diferenciales lineales y no lineales.

2.2.4.2 Diagnostico y detección con modelos del proceso. Se conocen como modelos de caja gris, también llamados sistemas inferenciales, basados en reglas. Su principal características de identificación son los parámetros, variables de estado y variación.

Usan herramientas como: ecuaciones de paridad, estimadores de estado o parámetros y análisis de componentes principales (PCA), entre los más importantes.

2.2.4.3 Diagnostico y detección con modelos basados en razonamiento y sistemas de aprendizaje. Son sistemas de modelamiento experimental, donde se establecen relaciones entre entradas y salidas y se asume una estructura interna del modelo. (ver figura 24)

Figura 24. Modelo matemático.



Fuente: Libro Feedback Systems: An Introduction for Scientists and Engineers.

Son sistemas muy confiables, llamados también “caja negra” y son muy usados en el campo de la detección y diagnóstico de fallas.

Entre los sistemas más importantes de este tipo de modelos, están las REDES NEURONALES (ANN) y las Maquinas de soporte Vectorial (SVM).

Las técnicas de Inteligencia Artificial se aplican hoy en día a diferentes problemas de Ingeniería, especialmente para la solución a un problema complejo. Teniendo en cuenta lo anterior, el desarrollo del presente trabajo se va a realizar usando las Reden Neuronales Artificiales, por ser uno de los métodos más eficaces y mayormente usados para la detección y diagnóstico de fallas en el área de mantenimiento y confiabilidad.

2.3 REVISIÓN BIBLIOGRÁFICA

Las bombas son ampliamente usadas en diferentes procesos de la industria y son pieza vital de muchos de los procesos productivos, ya que su función permite mover diferentes productos. Su función es indispensable para la operación de procesos dinámicos y esto hace que sean equipos críticos. Dada su criticidad, es necesario que estos equipos sean operados, mantenidos y optimizados para obtener su mayor provecho y extender su ciclo de vida y evitar impactos a las personas e instalaciones.

Las bombas centrifugas constantemente operan bajo condiciones extremas por las diferentes variables que se presentan en su funcionamiento, lo cual desencadena aparición de fallas de diferentes formas con sus respectivos efectos.

Teniendo en cuenta lo anterior es necesario contar con un método que nos ayude a la detección temprana de fallas, con el fin de reducir sus impactos, tanto económicos (costos de reparación) y de proceso que puedan afectar la integridad de personas e instalaciones.

El uso de las redes neuronales artificiales (ANN) como herramienta para la detección y diagnóstico de fallas en equipos, es una técnica de última generación y

aunque poco conocida realmente es de gran utilidad para los profesionales encargados de gestionar el mantenimiento en los diferentes equipos.

Se pretende demostrar que con el uso de las redes neuronales artificiales en el diagnóstico y detección de fallas en equipos, se puedan tener mayores disponibilidades y mejorar la mantenibilidad de los equipos, optimizando recursos y costos en las empresas. Esto al final permite mejorar la confiabilidad de nuestros sistemas.

Realizando una revisión bibliográfica sobre el tema, encontramos varios autores que hablan sobre la importancia y los métodos de realizar la detección y diagnóstico de fallas con diferentes herramientas disponibles actualmente, sin embargo nos centraremos específicamente en como utilizan las redes neuronales para la detección y diagnóstico de fallas en bombas centrífugas.

Isermann¹⁵ en su publicación expone que para mejorar la confiabilidad, la seguridad y la eficiencia de los procesos, los métodos avanzados de supervisión, detección de fallas y diagnóstico de fallas se convierten en una herramienta cada vez más importante para muchos procesos, especialmente a procesos relacionados con la seguridad en Plantas químicas. Los enfoques clásicos no ofrecen una visión muy profunda y por lo general, no permiten un diagnóstico de fallas; por lo que se desarrollaron métodos de detección de fallas basados en modelos mediante el uso de señales de entrada y salida y su aplicación en modelos de procesos dinámicos.

Estos métodos se basan en la estimación de parámetros, ecuaciones de paridad, entre otros, en donde el objetivo es generar varios síntomas. En función de los diferentes síntomas, se describen los procedimientos de diagnóstico de fallas, que determinan la falla aplicando una clasificación o inferencia.

¹⁵ ISERMANN. Model-based fault-detection and diagnosis – status and applications. Institute of Automatic Control, Darmstadt University of Technology, Germany. 2004

Aranguren¹⁶ en su artículo, muestra de forma general los métodos más usados como técnicas de detección y diagnóstico de fallas en procesos industriales y allí muestra como las redes neuronales (ANN) son bastante confiables.

En forma similar Hurtado y Villareal¹⁷ realizan un estado del arte sobre las técnicas de inteligencia artificial y su aplicación al campo de la detección y diagnóstico de fallas en sistemas dinámicos realizando un comparativo de las diferentes técnicas resaltando las fortalezas y debilidades de cada una de ellas y donde compara el uso de las ANN frente a otras técnicas.

Borras¹⁸ en su libro Técnicas avanzadas de mantenimiento profundiza en las diferentes técnicas para el diagnóstico y detección de fallas en sistemas, para mantener la confiabilidad y seguridad de los mismos. Dentro de las técnicas expuestas en el libro, se encuentra el uso de redes neuronales para reconocimiento de patrones.

Rajakarunakaran, Devaraj y Suryaprakasa¹⁹ en su artículo publicado hablan sobre la importancia de la detección y diagnóstico de fallas en plantas y su aporte a la seguridad. Muestran que una detección temprana de fallas puede ayudar a evitar el deterioro de los equipos, daños a la maquinaria y daños a las personas. El artículo presenta el diseño y desarrollo de un modelo basado en la Red Neural Artificial (ANN) para la detección de fallos en el sistema de bombeo centrífugo. La red mostrada en el artículo está desarrollada para detectar un total de 20 fallas. Los

¹⁶ ARANGUREN. Metodologías y tecnologías de detección y diagnóstico de fallas aplicadas a procesos industriales. Revista Colombiana de Tecnologías de Avanzada. Universidad de Pamplona, 2009

¹⁷ HURTADO Y VILLAREAL. Fault detection and diagnosis through artificial intelligence techniques, a state of art. Facultad Tecnológica, Universidad Distrital Francisco José de Caldas, Bogotá, Colombia. 2016

¹⁸ BORRAS Carlos. Técnicas avanzadas de Mantenimiento. UIS, 2016

¹⁹ RAJAKARUNAKARAN, DEVARAJ Y SURYAPRAKASA. Artificial neural network approach for fault detection in rotary system. A.K College of Engineering, Department of Industrial Engineering, Anna University, Tamilnadu, India, 2007

datos de entrenamiento y pruebas requeridos para desarrollar el modelo de la red, fueron generados en diferentes condiciones de operación, creando varias fallas en tiempo real en un modelo experimental de laboratorio. Proponen un método de extracción de características basado en análisis para reducir la dimensión de las entradas y concluyen que el rendimiento de la red entrenada se considera satisfactorio para el diagnóstico.

Por su parte Maradey²⁰ en su tesis, se enfoca en el diagnóstico de fallas en bombas Hidráulicas de pistones axiales por medio de redes neuronales con buenos resultados en este tipo de equipos, logrando buenos indicadores en las etapas de entrenamiento y pruebas de las redes aplicadas. Para desarrollar su trabajo estableció una metodología para analizar específicamente uno de los componente de este tipo de bombas y a partir de información de vibraciones y presión tomadas durante la operación de los equipos, realiza un análisis de datos y extracción de características para al final por medio de las ANN poder realizar el diagnostico y detecciones fallas.

Vargas²¹ en su trabajo de grado, establece a partir de una simulación mediante Matlab y el uso de Redes neuronales, un Modelo de gestión de mantenimiento para calcular la vida remanente de los equipos rotativos y mejorar la confiabilidad de bombas centrifugas específicamente, a partir de diferentes aspectos analizados, el cual aporta valiosa información para este trabajo. Para el desarrollo del modelo recopilo información de varios años de varios equipos que presentaron fallas asociadas a desgaste natural y con esto construyo el modelo usando varias clases de ANN, para comparar los resultados y elegir la mejor opción.

²⁰ MARADEY, Jessica. Diagnóstico de fallas en bombas hidráulicas de Pistones axiales, aplicando Redes Neuronales (ANN'S). Tesis Universidad Industrial de Santander, 2017

²¹ VARGAS, W. Elaborar un Modelo de Gestión de Confiabilidad en Mantenimiento basado en Supervisión Automática y control operativo para bombas centrifugas de las Plantas de Hidrotratamiento de la GRB. Tesis Universidad Industrial de Santander, 2017

De forma similar, Pérez²² en su tesis de grado, utiliza las redes neuronales para desarrollar un modelo de diagnóstico y detección de fallas en los diferentes componentes de bombas de un sistema de enfriamiento, resaltando la efectividad de las ANN para mejorar la confiabilidad, disponibilidad y mantenibilidad de los equipos estudiados. El utiliza como datos de entrada para la elaboración del modelo el análisis de vibraciones mecánicas del sistema. Para obtener resultados adecuados usa dos tipos de ANN para comparar los datos de salida y elegir los más adecuados.

Finalmente, con el uso de las Redes Neuronales Artificiales para el desarrollo de este proyecto buscamos usar uno de los métodos más prácticos y confiables para la detección y diagnóstico de fallas. Tenemos un amplio número de trabajos, en donde se usan con gran éxito por los resultados obtenidos.


2.4 REDES NEURONALES ARTIFICIALES

Las redes neuronales son un campo muy importante dentro de la Inteligencia Artificial. Inspirándose en el comportamiento conocido del cerebro humano (principalmente el referido a las neuronas y sus conexiones), trata de crear modelos artificiales que solucionen problemas difíciles de resolver mediante técnicas algorítmicas convencionales. La figura 25 representa la Red neuronal biológica.²³

²² PEREZ, Hugo. Modelo para análisis de Riesgo en las bombas del sistema de enfriamiento mediante el uso de Redes Neuronales. Tesis Universidad Industrial de Santander, 2017

²³ GOOGLE Unidad 4 redes neuronales [en línea] [citado el: 01 de diciembre de 2018]. Disponible en: www://sites.google.com/site/mayinteligenciartificial/unidad-4-redes-neuronales

Figura 25. Red neuronal biológica.



Fuente: SISTEMAS MANUFACTURA Sesión 22 [en línea] disponible en: www.sistemasmanufactura.files.wordpress.com/2011/05/sesion-22.pdf

Las redes neuronales no son más que un modelo artificial y simplificado del cerebro humano, que es el ejemplo más perfecto del que disponemos para un sistema que es capaz de adquirir conocimiento a través de la experiencia. Una red neuronal es *“un nuevo sistema para el tratamiento de la información, cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano: la neurona”*.²⁴

2.4.1 Historia de las Redes Neuronales Artificiales (ANN). Las redes Neuronales artificiales (ANN) nacen con la necesidad que tiene el hombre para resolver problemas complejos donde trata de simular el funcionamiento del cerebro para el procesamiento de gran cantidad de información.

Los primeros en dar explicaciones teóricas sobre el cerebro fueron Platón (427-347 A.C), Aristóteles (348-422 A.C.) y Descartes (1569-1650).²⁵

²⁴ MATICH, Damián. Redes Neuronales: Conceptos Básicos y Aplicaciones. Universidad Tecnológica Nacional – Facultad Regional Rosario Departamento de Ingeniería. 2001. 8p.

²⁵ PEREZ, Hugo. Modelo para análisis de Riesgo en las bombas del sistema de enfriamiento mediante el uso de Redes Neuronales. Tesis Universidad Industrial de Santander, 2017.

En 1936, Alan Turing, fue el primero en estudiar el cerebro como una forma de ver el mundo de la computación. Sin embargo, los primeros teóricos que concibieron los fundamentos de la computación neuronal fueron Warren McCulloch, un neurofisiólogo, y Walter Pitts, un matemático, quienes, en 1943, lanzaron una teoría acerca de la forma de trabajar de las neuronas. Ellos modelaron una red neuronal simple mediante circuitos eléctricos.²⁶

Para 1949, Donald Hebb, fue el primero en explicar los procesos del aprendizaje desde un punto de vista psicológico, desarrollando una regla de como el aprendizaje ocurría. Aun hoy, este es el fundamento de la mayoría de las funciones de aprendizaje que pueden hallarse en una red neuronal. Su idea fue que el aprendizaje ocurría cuando ciertos cambios en una neurona eran activados. También intentó encontrar semejanzas entre el aprendizaje y la actividad nerviosa. Los trabajos de Hebb formaron las bases de la Teoría de las Redes Neuronales.

Luego, en 1950, Karl Lashley, en sus series de ensayos, encontró que la información no era almacenada en forma centralizada en el cerebro sino que era distribuida encima de él. Para 1956, se realiza el Congreso de Dartmouth, en el cual frecuentemente se menciona para indicar el nacimiento de la inteligencia artificial.

Frank Rosenblatt en 1957, inicio el desarrollo del Perceptron. Esta es la red neuronal más antigua; utilizándose hoy en día para aplicación como identificador de patrones. Este modelo era capaz de generalizar, es decir, después de haber aprendido una serie de patrones podía reconocer otros similares, aunque no se le hubiesen presentado en el entrenamiento. Sin embargo, tenía una serie de limitaciones, por su incapacidad para clasificar clases no separables linealmente.

²⁶ MATICH, Damián. Redes Neuronales: Conceptos Básicos y Aplicaciones. Universidad Tecnológica Nacional – Facultad Regional Rosario Departamento de Ingeniería. 2001. 8p

Para 1959 Rosenblatt, con el libro “Principios de Neurodinámica”, confirma que, bajo ciertas condiciones, el aprendizaje del Perceptron convergía hacia un estado finito (Teorema de Convergencia del Perceptron).

En 1960, Bernard Widroff y Marcian Hoff, desarrollaron el modelo ADALINE (ADaptative LINear Elements). Esta fue la primera red neuronal aplicada a un problema real en filtros adaptativos para eliminar ecos en las líneas telefónicas, que se ha utilizado comercialmente durante varias décadas.

Luego, en 1969, se produjo la “muerte abrupta” de las Redes Neuronales; ya que Minsky y Papert probaron (matemáticamente) que el Perceptron no era capaz de resolver problemas relativamente fáciles, tales como el aprendizaje de una función no-lineal. Esto demostró que el Perceptron era muy débil, dado que las funciones no-lineales son extensamente empleadas en computación y en los problemas del mundo real.

Durante 1974, Paul Werbos, desarrolló la idea básica del algoritmo de aprendizaje de propagación hacia atrás (backpropagation); cuyo significado quedó definitivamente aclarado en 1985.

En 1977, Stephen Grossberg, propone la Teoría de Resonancia Adaptada (TRA). La Teoría de Resonancia Adaptada es una arquitectura de red que se diferencia de todas las demás previamente inventadas. La misma simula otras habilidades del cerebro: memoria a largo y corto plazo.

Finalmente en 1985, John Hopfield, provocó el renacimiento de las redes neuronales con su libro: “Computación neuronal de decisiones en problemas de optimización” y en 1986, David Rumelhart y G. Hinton, redescubrieron el algoritmo de aprendizaje de propagación hacia atrás (backpropagation).


A partir de 1986, el panorama fue alentador con respecto a las investigaciones y el desarrollo de las redes neuronales.

En la actualidad, son numerosos los trabajos que se realizan y publican cada año, las aplicaciones nuevas que surgen (sobre todo en el área de control) y las empresas que lanzan al mercado productos nuevos, tanto hardware como software (sobre todo para simulación), las cuales usan las redes neuronales como base de simulación.

Gracias a diferentes grupos de investigación en universidades de todo el mundo, las redes neuronales han alcanzado una madurez muy aceptable y se usan en todo tipo de aplicaciones como reconocimiento de patrones, voz y vídeo, compresión de imágenes, estudio y predicción, aplicaciones de apoyo a la medicina., todo tipo de aplicaciones que necesiten el análisis de grandes cantidades de datos, entre otros.

2.4.2 Tipos de Redes neuronales. La arquitectura de red neuronal más empleada es la Perceptrón Multicapa MLP (Multilayer Perceptron) alimentada hacia adelante, la cual es entrenada por medio del algoritmo de Back propagation para reducir el error cuadrático. Otras arquitecturas de red neuronal artificial que se pueden usar para el desarrollo de modelos son las redes dinámicas, gracias a que estas redes contienen retardos o memorias para almacenar información, se pueden ver en la figura 26, donde se pueden encontrar los diferentes tipos de redes neuronales.

Figura 26. Tipos de redes Neuronales.



Fuente: MARADEY, Jessica. Diagnóstico de fallas en Bombas Hidráulicas de Pistones Axiales, aplicando redes neuronales Artificiales. Tesis de Maestría, Bucaramanga: Universidad Industrial de Santander. 2017 47 p.

A continuación se mencionan los tipos de arquitectura de red neuronal empleadas para la detección de fallas en equipos industriales, y las arquitecturas empleadas en aplicaciones de predicción para el aprendizaje de sistemas dinámicos variables en el tiempo, las cuales se encuentran programadas dentro de MATLAB. ²⁷ , ²⁸


2.4.2.1 Red Neuronal Dinámica Son aquellas que contienen retardos y que operan en una secuencia de entradas ordenadas. Estas redes tienen memoria y su respuesta no solo depende de la entrada, sino también del histórico de una secuencia de entradas. Este tipo de redes tiene aplicación en diversas áreas como control dinámico, predicciones en el área financiero, detección de fallas, entre otras. Los algoritmos de entrenamiento de la redes dinámicas son backpropagation through-time (BPTT) y real-time recurrent learning (RTRL), de las cuales esta última es más eficiente ya que puede ser implementada en la vida real.

²⁷ VARGAS, William. “Elaborar un modelo de gestión de Confiabilidad en mantenimiento, basado en supervisión automática y control operativo para las bombas centrífugas para las Planta de Hidrotratamiento de la GRB” Trabajo de grado en maestría. UIS. 2017. 37 p.

²⁸ HAGAN, Martin y otros. Neural network design, tomo 20. PWS publishing company. Boston, 1996.

2.4.2.2 Red Neuronal Feedforward o Perceptron Multicapa La red neuronal Feedforward (ver figura 27), consiste en una serie de capas, la primera capa tiene una conexión con la capa de entrada y cada una de las capas subsecuentes tiene conexión con la capa previa. La capa final produce la salida de la RN. Este tipo de red es entrenada por medio del algoritmo back propagation, el cual calcula los gradientes locales de cada neurona y gradualmente va ajustando sus pesos y byas para minimizar el error cuadrático.

Figura 27. Red neuronal Feedforward.




Fuente: HAGAN, Martin y otros Neural network design.

2.4.2.3 Red Neuronal basada en retardos del tiempo. La red neuronal basada en retardos de tiempo (ver figura 28), es un tipo de red neuronal dinámica empleada para realizar predicciones de series temporales con aplicación en la detección y predicción de fallas²⁹.

²⁹ VARGAS, William. "Elaborar un modelo de gestión de Confiabilidad en mantenimiento, basado en supervisión automática y control operativo para las bombas centrífugas para las Planta de Hidrotratamiento de la GRB" Trabajo de grado en maestría. UIS. 2017. 37 p.


Figura 28. Red neuronal basada en retardos de tiempo.



Fuente: HAGAN, Martin y otros Neural network design.

2.4.2.4 Red Neuronal Narx La red neuronal tipo NARX (Nonlinear autoregressive model with exogenous input), es un tipo de red neuronal dinámica, empleada para la redacción de series temporales y reconocimiento de patrones dinámicos (ver figura 29).

Figura 29. Red neuronal NARX.



Fuente: HAGAN, Martin y otros Neural network design.

En el área del mantenimiento en los últimos años los Diseñadores, Ingenieros y técnicos han encontrado en las ANN un gran apoyo y herramienta tecnológica, ya que mediante el uso de estas, se pueden llegar a predecir, diagnosticar y clasificar los diferentes tipos de fallas que puede presentar un equipo. De tal forma que se pueden diseñar y aplicar diferentes tipos de estrategias de mantenimiento que permitan mejorar la confiabilidad, disponibilidad y mantenibilidad de los sistemas, lo

cual repunta en optimización de costos, recursos y eliminación de riesgos de impacto a personas e instalaciones.


2.4.3 Funcionamiento de una Red Neuronal Artificial (ANN) El funcionamiento de una ANN es muy similar al de las redes neuronales biológicas. Los científicos a lo largo del tiempo han tratado de copiar su funcionamiento y por medio de complejos algoritmos han logrado llegar a modelos que copian y se comportan como las redes neuronales Biológicas.³⁰

De forma similar en las ANN, la principal unidad se puede llamar neurona artificial, siendo esta unidad procesadora con posibilidad de combinar entradas, siendo modificada por medio de una función de transferencia para pasar directamente a la entrada de otra neurona si lo requiere.

Una neurona consta de una entrada (X), ponderadas por un peso (W). Los valores de entrada pueden ser enteros, reales o binarios. La unión de X y W equivalen a las señales de excitación y que inducen a la neurona a cambiar su comportamiento. (ver figura 30)

³⁰ BORRAS PINILLA, Carlos. Pattern recognition in hydraulic cylinders with blackwash using neural network. Tesis de MAestria. Oklahoma: University of Oklahoma. School of Aerospace and Mechanical Engineering, 2001, 113p.

Figura 30. Modelo simplificado de la Neurona.



Fuente: ANALÍTICA WEB La predicción del dato redes neuronales artificiales [en línea] disponible en: <https://www.analiticaweb.es/la-prediccion-del-dato-redes-neuronales-artificiales/>

Se expresa de la siguiente forma:

$$S = X * W$$

Donde:


S es la salida

X es el vector de entrada

W es el vector de peso

2.4.4 Arquitectura de una red neuronal La arquitectura de una red neuronal es la estructura o patrón de conexiones de la red. En general, las neuronas suelen agruparse en unidades estructurales llamadas capas. En la Figura 31, se presenta un esquema de una red neuronal. La misma está constituida por neuronas interconectadas y arregladas en tres capas (las cuales pueden variar). Los *datos* ingresan por medio de la “**capa de entrada**”, pasan a través de la “**capa oculta**” y salen por la “**capa de salida**”.

Figura 31. Ejemplo de una red neuronal totalmente conectada.



Fuente: PYTHON DIARIO Introducción a las Redes Neuronales - Parte #1: Elementos básicos de una Red Neuronal. [en línea] disponible en http://www.pythondiario.com/2018/07/introduccion-las-redes-neuronales-parte_12.html

Se pueden distinguir tres tipos de capas:

De entrada: reciben datos o señales procedentes del entorno.

De salida: proporcionan la respuesta de la red a los estímulos de la entrada.

Ocultas: no reciben ni suministran información al entorno (procesamiento interno de la red).

Generalmente las conexiones se realizan entre neuronas de distintas capas, pero puede haber conexiones intracapa o laterales y conexiones de realimentación que siguen un sentido contrario al de entrada-salida.

2.4.4.1 Elementos básicos de una red neuronal. Estos son los elementos básicos que componen una red neuronal:

Función de entrada.

Los valores de entrada se multiplican por los pesos anteriormente ingresados a la neurona. Entonces, los pesos cambian la medida de influencia que tienen los valores de entrada. Es decir, que permiten que un gran valor de entrada tenga solamente una pequeña influencia, si estos son lo suficientemente pequeños.

Función de activación

Una neurona puede estar activa o inactiva; es decir, tiene un “estado de activación”. Las neuronas artificiales, tienen diferentes estados de activación; algunas de ellas solamente dos, al igual que las biológicas, pero otras pueden tomar cualquier valor dentro de un conjunto determinado.

La función activación calcula el estado de actividad de una neurona; transformando la entrada en un valor (o estado) de activación, cuyo rango normalmente va de (0 a 1) o de (-1 a 1). Esto es así, porque una neurona puede estar totalmente inactiva (0 o -1) o activa (1).

Las funciones de activación más comúnmente utilizadas se detallan a continuación en la Figura 32:

Figura 32. Funciones de activación de redes neuronales



Fuente: AVELLANO [en línea] disponible en:
<http://avellano.fis.usal.es/~lalonso/RNA/index.htm>

Función de salida

El último componente que una neurona es la función de salida. El valor resultante de esta función es la salida de la neurona. Normalmente, no cualquier valor es permitido como una entrada para una neurona, por lo tanto, los valores de salida están comprendidos en el rango $[0, 1]$ o $[-1, 1]$, o pueden ser binarios $\{0, 1\}$ o $\{-1, 1\}$.

2.4.5 Aprendizaje de las Redes Neuronales Artificiales. El aprendizaje de las redes neuronales, es el proceso por el cual una RNA actualiza los pesos y, en algunos casos, la arquitectura, con el propósito de que la red pueda llevar a cabo de forma efectiva una tarea determinada.

Hay tres conceptos fundamentales en el aprendizaje:

2.4.5.1 Paradigma de aprendizaje Es la información de la que dispone la red neuronal. Existen dos paradigmas fundamentales de aprendizaje:

Supervisado

La red trata de minimizar un error entre la salida que calcula y la salida deseada (conocida), de modo que la salida calculada termine siendo la deseada.

No supervisado o auto organizado

La red conoce un conjunto de patrones sin conocer la respuesta deseada. Debe extraer rasgos o agrupar patrones similares.

Los algoritmos, y en general el proceso de aprendizaje de las redes neuronales, son complejos y suelen llevar bastante tiempo, siendo una de sus principales

desventajas. Sin embargo una vez ha aprendido, la red puede congelar sus pesos y funcionar en modo recuerdo o ejecución.³¹

2.4.5.2 Reglas de aprendizaje Son los principios que gobiernan el aprendizaje de la red neuronal.

2.4.5.3 Algoritmo de aprendizaje Es el procedimiento numérico de ajuste de los pesos de la red neuronal.

2.4.6 Ventajas de las redes neuronales. Las redes Neuronales han atraído la atención de los investigadores debido a su capacidad para aprender funciones no lineales complejas. Son capaces de aprender de la experiencia, de generalizar de casos anteriores a nuevos casos, de abstraer características esenciales a partir de entradas que representan información irrelevante, etc. Esto hace que ofrezcan numerosas ventajas y que este tipo de tecnología se esté aplicando en múltiples áreas. Entre las ventajas que ofrece el uso de las redes neuronales, tenemos:³²

2.4.6.1 Aprendizaje Adaptativo. Es decir, tienen la capacidad de aprender a realizar tareas basadas en un entrenamiento o en una experiencia inicial.

2.4.6.2 Auto-organización. Una red neuronal puede crear su propia organización o representación de la información que recibe mediante una etapa de aprendizaje.

2.4.6.3 Tolerancia a fallos. La destrucción parcial de una red conduce a una degradación de su estructura; sin embargo, algunas capacidades de la red se pueden retener, incluso sufriendo un gran daño.

³¹ QUISPE, Nelson. Redes Neuronales Artificiales, Metodología de Desarrollo y Aplicaciones. [en línea] Disponible en: <https://www.monografias.com/trabajos95/redes-neuronales-artificiales-metodologia-desarrollo-y-aplicaciones/redes-neuronales-artificiales-metodologia-desarrollo-y-aplicaciones.shtml>

³² MATICH, Damián. Redes Neuronales: Conceptos Básicos y Aplicaciones. Universidad Tecnológica Nacional – Facultad Regional Rosario Departamento de Ingeniería. 2001. 8p.

2.4.6.4 Operación en tiempo real. Los cálculos neuronales pueden ser realizados en paralelo; para esto se diseñan y fabrican máquinas con hardware especial para obtener esta capacidad.

2.4.6.5 Fácil inserción dentro de la tecnología existente. Se pueden obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilitará la integración modular en los sistemas existentes.

2.4.7 Desventajas del uso de las redes neuronales. Aunque son más la ventajas de este tipo de herramientas, por ser complejas, también presentan algunas desventajas, las cuales se pueden superar y con la experiencia, se logra minimizar su impacto en el desarrollo y uso de las redes neuronales. Algunas de las desventajas son:


2.4.7.1 Diseño y entrenamiento Su diseño es complejo, requiere conocimientos técnicos básicos en algunas áreas y su entrenamiento es también dispendioso, sin embargo después de superadas estas etapas, son muy útiles y confiables.

2.4.7.2 Tiempo de aprendizajes Su tiempo de aprendizaje es un poco elevado, sin embargo esto les permite reentrenarse y ser más exactas. Esto varía dependiendo del tipo de red utilizada y de la calidad de la información suministrada a la red.

2.4.7.3 Cantidad de datos requeridos Para su entrenamiento, aprendizaje y buen funcionamiento, se requiere una cantidad de datos suficientes, para que sea más confiable. A mayor cantidad de información suministrada a la red, mejor es su desempeño.

En la figura 33, podemos ver agrupadas las ventajas y desventajas del uso de redes neuronales en cualquier campo de investigación.

Figura 33. Ventajas y desventajas de la Redes neuronales.




2.4.8 Estructura de las redes neuronales. La topología o arquitectura de una red neuronal consiste en su organización y disposición de las neuronas en la misma, formando capas. En este sentido, los parámetros fundamentales de la red son el número de capas, el número de neuronas por capa, el grado de conectividad y el tipo de conexiones entre neuronas.

2.4.8.1 Redes mono capa. En las redes mono capa, se establecen conexiones entre las neuronas que pertenecen a la única capa que constituye la red. Se utilizan generalmente en tareas como auto asociación (regenerar información que se presenta a la red de forma incompleta o distorsionada).

2.4.8.2 Redes multicapa Las redes multicapas son aquellas que disponen de un conjunto de neuronas agrupadas en varios niveles o capas. (ver figura 34) Una forma para distinguir la capa a la que pertenece una neurona, consistiría en fijarse en el origen de las señales que recibe a la entrada y el destino de la señal de salida. Normalmente, todas las neuronas de una capa reciben señales de entrada desde otra capa anterior y envían señales de salida a una capa posterior. A estas conexiones se las denomina conexiones hacia adelante o **feedforward**.

Sin embargo, en un gran número de estas redes también existe la posibilidad de conectar la salida de las neuronas de capas posteriores a la entrada de capas anteriores. A estas conexiones se las denomina conexiones hacia atrás o **feedback**.

Figura 34. Redes Multicapa.



Fuente: REDES-NEURONALES Las redes neuronales multicapa [en línea] disponible en: <http://www.redes-neuronales.com.es/tutorial-redes-neuronales/Las-redes-neuronales-multicapa.htm>

2.4.8.3 Conexión entre neuronas. La conectividad entre los nodos de una red neuronal está relacionada con la forma en que las salidas de las neuronas están canalizadas para convertirse en entradas de otras neuronas. La señal de salida de un nodo puede ser una entrada de otro elemento de proceso, o incluso ser una entrada de sí mismo (conexión autor recurrente). Cuando ninguna salida de las neuronas es entrada de neuronas del mismo nivel o de niveles precedentes, la red se describe como de conexión hacia delante.

Cuando las salidas pueden ser conectadas como entradas de neuronas de niveles Previos o del mismo nivel, incluyéndose ellas mismas, la red es de conexión hacia Atrás. Las redes de propagación hacia atrás que tienen lazos cerrados son llamadas Sistemas recurrentes.

2.4.8.4 Redes de propagación hacia atrás (backpropagation). El nombre de backpropagation resulta de la forma en que el error es propagado hacia atrás, o en otras palabras el error se propaga hacia atrás desde la capa de salida. Esto permite que los pesos sobre las conexiones de las neuronas ubicadas en las capas ocultas cambien durante el entrenamiento. El cambio de los pesos en las conexiones de las neuronas además de influir sobre la entrada global, influye en la activación y por consiguiente en la salida de una neurona.

Por lo tanto, es de gran utilidad considerar las variaciones de la función activación al modificarse el valor de los pesos. Esto se llama sensibilidad de la función activación, de acuerdo al cambio en los pesos.

2.4.9 Aplicaciones de las redes neuronales. Las redes neuronales pueden utilizarse en un gran número y variedad de aplicaciones, con la capacidad de realizar tareas concretas mejor que otras tecnologías, ya que presentan una alta tolerancia a fallos del sistema y proporcionan un alto grado de procesamiento de datos y confiabilidad.

Esto posibilita la inserción de redes neuronales en sistemas existentes y recientemente desarrollados. Hay varios tipos de redes neuronales; cada uno de los cuales tiene una aplicación particular más apropiada.

Algunas aplicaciones comerciales son:

- Biología
- Finanzas
- Medio ambiente

- Finanzas
- Manufacturación
- Medicina
- Militares

La mayoría de estas aplicaciones consisten en realizar un reconocimiento de patrones, clasificar patrones, completar una señal o reconstruir el patrón correcto partiendo de uno distorsionado. Sin embargo, está creciendo el uso de redes neuronales en distintos tipos de sistemas de control.

2.5 CASO BOMBAS CENTRIFUGAS DE DIESEL PRODUCTO

2.5.1. Características del equipo de bombeo. Los equipos en estudio para el desarrollo del presente proyecto, son bombas centrifugas mono etapa tipo BB2 (between bearing), dividida radialmente con impulsor doble succión, como se ve en la figura 35 y 36.

Figura 35. Bomba Tipo BBS.



Fuente: SULZER BBS and CD between bearings single stage pumps [en línea] disponible en: <https://www.sulzer.com/en/shared/products/2017/03/28/12/51/bbs-and-cd-between-bearings-single-stage-pumps>.

Figura 36. Bomba diésel producto de Diesel.



Esta bomba es la encargada de enviar el Diésel producto de la Unidad de Hidrotratamiento de Diésel hacia los tanques de producto final, donde se realiza la mezcla de este Diésel con otros productos de bajo azufre de la Refinería, para luego ser enviado hacia distintos lugares del país vía Poliducto o Carro tanque, para su distribución final a Estaciones de servicio y clientes usuarios de este producto, muy importante para la economía nacional, ya que es usado

especialmente como combustible en flotas de transporte de pasajeros y carga tipo urbano e intermunicipal.

Las características principales de esta bomba, se encuentran incluidas en su datasheet y curva de desempeño, el cual encontramos en el Anexo 1, al final del trabajo.

El diseño de esta bomba es de reciente tecnología, complejo y especial, debido a varios aspectos, como su alta capacidad, ya que su flujo normal de operación está cercano a los 120.000 BPD, con una temperatura del producto cercano a los 650 °F (diésel con temperatura de auto ignición de 585 °F), la cual esta accionada mecánicamente por un motor eléctrico asíncrono de 500HP de potencia, lo que la hace una de las bombas más grandes en la Refinería de Barrancabermeja. Su presión de succión y descarga son 21 psig y 170 psig respectivamente.

2.5.2 Sistemas de protección de las bombas de diesel producto. Debido a las características del producto, el flujo manejado y su temperatura, hacen que este equipo sea considerado de alta criticidad ASP (Administración de seguridad de procesos), debido a que una falla en este equipo puede llegar a ocasionar altos impactos en las personas, instalaciones y la producción de combustibles en el país.

Es por lo anterior que estas bombas están provistas de varias capas de seguridad, las cuales protegen a las personas, el sistema propio y las instalaciones de las consecuencias de cualquier falla. Estos sistemas de protección son:

Sistemas de corte. Para proteger las personas y las instalaciones estos equipos están provistos de un sistema de disparo remoto y local, con el cual ante cualquier evento de proceso (nivel, temperatura, vibración o presión), fuga, el equipo de para y automáticamente unas válvulas de corte se cierran a la succión y descarga, para evitar cualquier fuga de producto, como lo muestra la figura 37.

Figura 37. Válvulas de corte sistema de corte.



Sistema de detección de fuego y gas (F&G). Este sistema protege a las personas y el equipo ante cualquier evento de incendio, escape o presencia de gases, el cual actúa una alarma sonora y visual en el área y automáticamente actúa un sistema de diluvio con agua para sofocar cualquier fuga o incendio. En caso de presentarse este evento, el Operador del equipo puede activar también el sistema de corte para mayor protección. (ver figura 38)

Figura 38. Sistema de diluvio bombas de diesel producto.




Plan de sellado con sello doble. Estas bombas tienen instalados en sus planes de sellado, en cada uno de los extremos del eje, (por ser una bomba tipo between bearing), cartuchos duales 21-53B con tecnología especial y los cuales ofrecen

mayor seguridad a la hora de evitar fugas al ambiente, como se muestra en la figura 39.

El plan API 53B es una circulación forzada por un anillo de bombeo, de líquido de barrera, el cual está contenido en un circuito cerrado presurizado. Un acumulador de tipo vejiga provee y mantiene la presión en el sistema de circulación. El calor es removido por un intercambiador, enfriado por agua.


Figura 39. Plan de sellado 53B.



Fuente: JOHN CRANE [en línea] disponible en: www.johncrane.com.


El plan API 21 es una Circulación desde la descarga hasta la cavidad de sellado pasando por una placa orificio y un intercambiador de calor. El calor es removido por un intercambiador, enfriado por agua. (ver figura 40 y 41)

Figura 40. Sistema de sello con plan 21.



Fuente: JOHN CRANE [en línea] disponible en: www.johncrane.com.


Figura 41. Sistema de sellado plan 21/53B.



Monitoreo en línea. Las bombas en estudio están monitoreadas continuamente en línea bajo dos sistemas:


El sistema de control distribuido (DCS), controla y monitorea los equipos y en general toda la unidad dentro de los parámetros establecidos en todas las variables necesarias para lo cual la unidad fue diseñada. Es decir, este sistema monitorea las variables de presión, temperatura, flujo y niveles relacionados al equipo, como lo indica la figura 42 y 43.

Figura 42. Sistema DCS bombas de diesel producto.



El sistema de monitoreo de vibraciones y temperaturas en línea, permite hacer seguimiento en tiempo real de la operación del equipo, con el cual se puede conocer su desempeño físico del mismo. Este sistema de monitoreo está instalado en el equipo dada su criticidad y con el cual se toman decisiones para ajustes operacionales, diagnóstico de fallas y programación de actividades de mantenimiento.

Figura 43. Sistema de monitoreo de Vibraciones bombas de diesel producto.



2.5.3 Fallas presentadas en las bombas de diesel producto. Como se mencionó anteriormente, este equipo ha presentado fallas recurrentes, en diferentes modos

de falla, los cuales han ocasionado un bajo Tiempo medio entre fallas (MTBF), ocasionando baja disponibilidad, altos costos de mantenimiento e impactos económicos y materiales.

Las fallas más presentadas en estos equipos son indicadas en la tabla 2:

Tabla 2. Cantidad de Modos de falla presentados en los equipos (tiempo de análisis 3 años).

MODO DE FALLA	CANT
Falla de sellos (fuga externa e interna)	7
Sobrecalentamiento (sistema de sello y flushing)	3
Desviación de parámetros (temperatura y presión)	2
Taponamiento/Restringido (enfriadores sello)	2
Vibración	1
Ruido	1
Rotura (eje)	1
Parada inesperada	1

2.5.3.1 Fugas internas/externas de medio auxiliar y de proceso. Son producidas por daños en el sistema de plan de sellado, cartuchos duales 21-53B al presentar fuga de líquido barrera hacía el interior o exterior del equipo, el cual se manifiesta por perdida de presión de líquido barrera, el cual debe ser mantenido lo más estable posible a su valor de operación (130 psig), mientras se interviene el equipo por mantenimiento.

También se ha presentado fuga de diésel producto hacia el exterior del equipo, siendo la falla más crítica, ya que al fugar diésel a 650 °F (por encima de su temperatura de auto ignición) y caer sobre superficies a alta temperatura

(temperatura propia del equipo), este se enciende, creando pequeños incendios, los cuales son detectados y controlados por el sistema F&G y el sistema de corte.

Esta falla del sistema de sellado, es una de las más comunes en estos equipos y se genera principalmente por daño en las caras de sellado, empaques (oring), resortes, entre otras partes internas del sello, según lo muestra la figura 44.

En los casos que se presenta esta falla, se procede a colocar en servicio el equipo relevo (stand by) y se para el equipo en falla con el fin de realizar la intervención de mantenimiento necesaria para recuperar su confiabilidad. Esta falla es crítica y se requiere atender con urgencia, con el fin de evitar algún tipo de incidente a las personas o instalaciones por la salida de producto inflamable a alta temperatura al ambiente.

Figura 44. Evidencias de falla en sistemas de sellado.



Desafortunadamente es una de las fallas más costosas, ya que por la tecnología y la complejidad del sistema de sellado, sumado a todo el procedimiento de mantenimiento para reemplazar estos sellos, se hace bastante dispendioso y extenso, haciéndose necesario retirar el equipo al taller, según figura 45.

Figura 45. Proceso de mantenimiento de una bomba de diesel producto.



2.5.3.2 Vibración y ruido. Se presenta por fallas en rodamientos radiales y/o axiales, daño o desbalanceo del eje o conjunto eje impulsor, debido a que el eje de esta bomba es de longitud considerable y el equipo opera con altas temperaturas, por lo cual se puede deflectar. Este tipo de falla, ha llegado a exigir cambio de los rodamientos, reparación y/o cambio del eje y balanceo dinámico del conjunto eje impulsor. La figura 46 muestra la falla de rodamientos y la intervención del equipo para su corrección.


Figura 46. Cambio de rodamientos de una bomba de diesel producto.



Otras condiciones que ocasionan vibraciones o ruido en este tipo de equipos, están asociadas a cavitación por bajo NPSH o condiciones de proceso como flujo inadecuado (alto o bajo dados en procesos de arranque y paro de la unidad).


El bajo NPSH, asociado a baja presión de succión, se manifiesta principalmente por obstrucción en el filtro de succión por llegada de material articulado, más específicamente trazas de carbón generadas por condiciones de alta temperatura en el proceso. (Craqueo térmico de hidrocarburos), las cuales se muestran en la figura 47.

Figura 47. Partículas en la succión de una bomba de diesel producto




En cuanto a vibraciones se refiere en este equipo, un espectro tomado durante su operación normal, según la figura 48, se evidencian los siguientes hallazgos:

Figura 48. Espectro de vibración de una bomba de diesel producto.



Una causa más de vibración o ruido en estos equipos, es una lubricación inadecuada. La bomba por ser tipo BBS (Between bearing) tiene 2 cajas de rodamientos con lubricación por salpique con aceite sintético, el cual permite operar los rodamientos de esta bomba a altas temperaturas, debido al proceso en donde opera. (ver figura 49) La lubricación es un punto muy crítico en este sistema, ya que por la exposición a las altas temperaturas, el aceite acelera su degradación, llevando la película lubricante al límite y generando riesgos de fallas en partes móviles por lubricación inadecuada.

Figura 49. Lubricación por salpique.



Fuente: RELIABILITY WEB Consejos útiles para aumentar la confiabilidad a través de la lubricación [en línea] disponible en: <https://reliabilityweb.com/sp/articles/entry/consejos-utiles-para-aumentar-la-confiabilidad-a-traves-de-la-lubricacion>

Cuando se presenta este tipo de falla en el equipo, se valora hasta donde el equipo puede continuar operando y si es necesario se saca de servicio para realizar su intervención y evitar fallas catastróficas. Su intervención comprende cambio de rodamientos en sitio y según estado del eje, se define si se balancea o no.

2.5.3.3 Sobrecalentamiento en sistema de flushing y líquido barrera. Estas bombas tienen instalado un plan de sellado, con cartuchos duales 21-53B, los cuales son muy sensibles si operan a temperaturas altas, ya que se presenta daño en las caras, camisa y empaquetaduras del sistema de sellado, entre otros.

Esta condición es debida principalmente a:

- Ensuciamiento del sistema de flushing y liquido barrera,
- Falla en los intercambiadores (rotura o corrosión) del sistema de flushing y liquido barrera del plan de sellado,
- Contaminación del agua de enfriamiento con lodos, hidrocarburos, entre otros.


Para corregir esta falla se procede a intervenir los enfriadores en sitio, realizando actividades de limpieza y pruebas para detectar fallas en la metalurgia del enfriador. Después de esto se normaliza nuevamente y se implementan actividades de mantenimiento básico con el fin de preservar su función. (ver figura 50)

Figura 50. Enfriador de sistemas de sello de una bomba de diesel producto.



2.5.3.4 Desviación de parámetros. Se tienen antecedentes de eventos de falla de equipos de bombeo por desviación de parámetros operacionales del sistema o proceso, los cuales suceden por diversas situaciones. Estos parámetros son asociados a condiciones propias de diseño de los equipos y del proceso como tal, los cuales están en seguimiento constante por el sistema de control distribuido (DCS) y por el Operador de consola, ayudado por un sistema de alarmas sonoras y visuales, las cuales muestran cuando un parámetro del proceso (presión, nivel, temperatura, flujo) se está saliendo de control bajo dos situaciones. La primera cuando la variable del proceso se sale de la guía de control (GC), que son los límites máximos y mínimos de control del proceso, y puede ocasionar afectaciones a calidad. La segunda cuando los valores de la variable se salen de la ventana operativa (VO), lo cual es inaceptable, ya que a partir de allí ya se está corriendo el riesgo de generar afectaciones en los equipos, personas, medio ambiente o la producción, debido a que ya se está afectando la integridad mecánica o de diseño de los equipos y sistemas, y esto puede llegar a desencadenar fallas de los mismos con consecuencias bastante considerables. (ver figura 51)

Figura 51. Límites de operación variables de proceso.



Los parámetros más importantes asociados al sistema son:

Nivel de succión. La bomba succiona diésel producto de una torre de proceso. Esta es una de las variables más críticas en la operación de la bomba, ya que si la bomba opera con un bajo nivel (NPSHr), puede ocasionar cavitación de la misma, generando fallas en algunos de los componentes del equipo (daño sellos, impulsor, vibraciones).

Presión de succión

Asociado a la cabeza de succión, es una variable crítica y de seguimiento en la operación del equipo, ya que puede ser señal de un bajo NPSH, asociado a bajo nivel de succión, obstrucción del filtro de succión de la bomba, obstrucción por falla de la válvula de corte o válvula bloque en la succión, entre otras. Cuando se presenta desviación de este parámetro, se procede a sacar de servicio el equipo para realizar intervención de mantenimiento, ya que en la mayoría de los casos se presenta obstrucción del filtro de succión por llegada de material articulado de tamaño mayor a mech de la malla del filtro de succión. Este efecto se puede apreciar de acuerdo a la figura 52, en donde se ve el tipo de material particulado que se encuentra en la succión de la bomba, el cual como dijimos anteriormente, se presenta por formación de carbón en el proceso.

Figura 52. Datos de diseño de NPSHr a la succión de la bomba.

— Data Point —	
Flow:	3921 US gpm
Head:	473 ft
Eff:	73.9%
Power:	419 hp
NPSHr:	12.3 ft
— Design Curve —	
Shutoff head:	571 ft
Shutoff dP:	163 psi
Min flow:	1413 US gpm
BEP:	73.9% @ 3924 US gpm
NOL power:	445 hp @ 4460 US gpm
— Max Curve —	
Max power:	831 hp @ 5519 US gpm

Flujo de la bomba.


Durante su operación normal, el flujo de la bomba es muy estable. Su flujo normal de operación es de 120 kilo barriles por día (KBPD). Este flujo lo componen 2 corrientes. La primera es la de la producción de la unidad, que es en promedio 65 KBPD. La segunda es un flujo de 55 KBPD, que de acuerdo al diseño se envía a calentar (aumentar temperatura) hacia el horno, con el fin de mantener las condiciones de temperatura al producto para el proceso desarrollado en la torre de proceso (destilación).

Este flujo hace que esta bomba sea de alta capacidad, por lo cual esta variable, afecta la operación confiable del equipo, debido al impacto de un alto o bajo flujo en la operación del equipo.

Sin embargo, durante procesos de arranque y parada, esta variable se afecta, afectando también la confiabilidad del equipo, ya que es un factor importante en la vida útil de componentes como sellos y rodamientos entre otros.

En la figura 53, podemos observar los efectos de operar una bomba centrífuga por fuera de los valores de su curva (Q-F).

Figura 53. Efectos de Operar bombas centrífugas por fuera de la zona dulce.



Fuente: DOCUMENTS Curso bombas Larry bachus [en linea] disponible en: <https://vdocuments.site/curso-bombas-larry-bachus.html>

Temperatura del producto

La temperatura del producto de este equipo, que en operación normal, está cercana a los 650 °F, además de ser peligrosa, ya que ante cualquier fuga, hay riesgo de incendio, también impacta la confiabilidad del equipo, ya que puede afectar directa o indirectamente los componentes del equipo como el mismo eje, que puede llegar a deflactarse, la calidad del aceite lubricante y por ende de los rodamientos, los cuales ante altas temperaturas y a pesar de usar aceites sintéticos, se ven afectados por esta variable. Igualmente y no menos importante, la vida de los sellos de este equipo se ve bastante afectada por la alta temperatura, y sumado a deficiencias de enfriamiento en los sistemas de flushing y liquido barrera del plan 21/53B, genera en mayor número las fallas en el sistema de sellado.

Para minimizar el impacto de esta variable en la confiabilidad de las bombas, se instaló aislamiento térmico al equipo, para proteger los sistemas de sellado y rodamientos del mismo de fallas catastróficas.

Ante cualquier desviación de los parámetros se debe actuar inmediatamente y realizar la corrección necesaria con el fin de que entren en control y la operación de la bomba sea dentro de los parámetros de diseño.

Esta actividad es netamente operativa y se debe hacer tan pronto sea detectada.

2.5.3.5 Rotura del eje. Se presenta por fractura del eje al momento de arrancar el equipo, por encontrarse a baja temperatura y estar atascado con material articulado dentro de la bomba, lo cual genera alto torque al momento del arranque, generando daño catastrófico del eje. Lo anterior debido a que la bomba opera con producto a alta temperatura, se requiere que este caliente al momento de colocar en servicio para evitar choques térmicos al interior de la bomba en el eje e impulsor. (ver figura 54)

Figura 54. Falla de eje de la bomba.



Ya que es una de las fallas más catastróficas presentadas, pos supuesto se hace la intervención necesaria en taller, lo que implica un mayor alcance de actividades de

mantenimiento que deben ir de la mano del manual del fabricante del equipo para asegurar la instalación o fabricación de los componentes de buena calidad y según parámetros de diseño.

2.5.3.6 Parada inesperada. Eventos de falla por parada inesperada se pueden presentar por varios motivos como: acción de sistemas de corte por bajo nivel de succión, altos valores de vibraciones, accionamiento de protecciones eléctricas (corriente, F.P.) paradas de emergencia o por procesos normales de arranque y parada la unidad en donde el equipo se ve afectado ya que por necesidades operativas se requiere hacer esta acción.

Independiente del motivo de la parada inesperada, esto puede ocasionar fallas en los diferentes componentes del equipo (rodamientos, sellos, eje e impulsor), por lo que se deben evitar mientras sea posible.


2.5.4 Análisis de fallas. Es indispensable para el desarrollo del presenta trabajo y sobre todo para recuperar la confiabilidad del sistema, realizar el análisis de la información recopilada acerca de las fallas presentadas, con el fin de estructurar los datos y poder desarrollar y evaluar el modelo propuesto en este trabajo.

Por lo anterior se deben analizar los modos de falla que se presentan o se pueden llegar a presentar en los equipos analizados, para poder establecer una base adecuada para el diseño del modelo propuesto.

Realizando un análisis y recopilación de las fallas presentadas, se identifica cual es la falla más frecuente en este equipo, identificando que el componente que más falla son los sellos mecánicos del equipo, al presentar 7 de las 18 fallas presentadas en un periodo de 3 años de evaluación.

Para observar el comportamiento de las fallas, se realiza un análisis de Pareto mostrado en la figura 55.


Figura 55. Falla de eje de la bomba.



Para el análisis de las fallas se realiza un análisis de causa raíz con el fin de establecer las posibles causas de los modos de falla más presentados en el equipo.

A continuación se encuentra el RCA donde se analizan las fallas de sellos, falla de rodamientos y daño de anillos de desgaste, el cual se indica con la figura 56.

Figura 56. Análisis causa efecto



3. ADQUISICIÓN DE DATOS

Para el desarrollo del trabajo y de acuerdo a los objetivos y metodología propuestos al inicio del proyecto se adquirió valiosa información, con el fin de utilizarla para la elaboración y verificación del modelo. Esta información es tomada de todos los sistemas asociados al equipo, por lo tanto son reales, verídicos y de manejo confidencial. Esto nos permitirá tener un modelo más exacto, confiable y con el poder realizar un buen diagnóstico y en especial la detección temprana de las fallas, con el fin de poder mejorar la confiabilidad, disponibilidad y mantenibilidad del equipo, para asegurar la operación confiable de las unidades y optimizar los costos asociados a los procesos de mantenimiento y operación del equipo en mención.

Los datos recopilados y asociados al equipo son adquiridos de dos formas:

3.1 ADQUISICIÓN AUTOMÁTICA

Son los datos tomados de forma automática por el sistema de control de la unidad, los cuales son grabados en un sistema independiente, los cuales son guardados por determinado tiempo para su consulta y análisis.

3.2 ADQUISICIÓN MANUAL

Son datos tomados de forma manual por el Personal de Operaciones mediante rondas realizadas durante los turnos diarios, esta información se almacena en un recolector de datos y finalmente es enviada al sistema de información de las unidades para su análisis, almacenamiento y consulta.

Sea cual sea el método de recolección de información, durante los procesos de recolección de los datos, los sistemas avisan al operador de DCS y Campo, cuando una variable de operación del equipo se encuentra fuera de su límite de operación normal o de su ventana de integridad, con el fin de que inmediatamente se realicen los ajustes necesarios para devolverla a sus valores normales.

Los datos recolectados y relacionados al proceso, pero que directamente o indirectamente afectan al equipo, como se dijo anteriormente, son la temperatura del producto, la presión de succión y descarga del equipo, el nivel de succión (asociado al NPSHr) y el flujo de operación.

De los sistemas auxiliares asociados al equipo, se tomaron datos asociados a las presiones y temperaturas del sistema de sello, las vibraciones y velocidad del equipo durante su operación.

Esta recolección de datos se realizó durante un periodo aproximado de 2 años, teniendo en cuenta que mayor cantidad de datos, permiten que la construcción del modelo sea más fiable y los resultados sean más confiables.

En la tabla 3 están categorizados los modos de falla presentados en el equipo, sus efectos de falla y las variables que nos muestran la presencia de las fallas, con las cuales se toman las decisiones.

Tabla 3. Categorización de fallas.

CLASE DE FALLA	CATEGORIA FALLA	EFECTO DE LA FALLA	CODIGO DESVIACION	VARIABLE	UNIDAD	RANGO	
						Vr MINIMO	Vr MAXIMO
FC-A	OPERACIÓN OPTIMA (Línea base)	Equipo opera en condiciones optimas sin presentar fallas (ESTADO NUEVO)	N/A	<i>Ver Hoja OPERACIÓN OPTIMA</i>			
FC-B	FALLA SELLO MECANICO	Se evidencia perdida de presion del liquido barrera del sistema de sello ocasionando fuga interna o externa de liquido barrera o producto, haciendo necesario sacar de servicio el equipo.	D1	PRESION DE SELLO LADO ACOPLE	psig	105	135
			D2	PRESION DE SELLO LADO EMPUJE	psig	105	135
			D3	TEMPERATURA DE SELLO	° F	85	135
			D4	TEMPERATURA DE FLUSHING	° F	85	325
			D5	VIBRACIONES	IN/SEC	0	0,16
			D6	FLUJO DE OPERACIÓN	BPD	105.000	158.000
			D8	TEMPERATURA PRODUCTO	° F	85	640
FC-C	FALLA RODAMIENTOS	Se evidencian altos valores de vibracion y ruido en los rodamientos, ocasionados por aspectos operacionales o lubricacion inadecuada, desalineacion y/o desbalanceo, haciendo necesario sacar de servicio el equipo.	D5	VIBRACIONES	IN/SEC	0	0,16
			D6	FLUJO DE OPERACIÓN	BPD	105.000	158.000
			D7	PRESION DE SUCCION	psig	18	24
			D8	TEMPERATURA PRODUCTO	° F	85	640
			D9	NIVEL DE SUCCION	%	35	70
FC-D	FALLA EN ENFRIADORES	Se evidencia alta temperatura en el sistema de sello o flushing, generando condiciones para falla de sellos, haciendo necesario sacar de servicio el equipo.	D3	TEMPERATURA DE SELLO	° F	85	135
			D4	TEMPERATURA DE FLUSHING	° F	85	325
			D6	FLUJO DE OPERACIÓN	BPD	105.000	158.000
			D8	TEMPERATURA PRODUCTO	° F	85	640
FC-E	FALLA EN EL EJE (PARADA INESPERADA)	Se evidencias por falla mecanica del eje e impulsor (rotura) lo cual deja inmediatamente el equipo.	D5	VIBRACIONES	IN/SEC	0	0,16
			D6	FLUJO DE OPERACIÓN	BPD	105.000	158.000
			D7	PRESION DE SUCCION	psig	18	24
			D8	TEMPERATURA PRODUCTO	° F	85	640
			D9	NIVEL DE SUCCION	%	35	70

En los anexos C al I (al final) se muestran los datos adquiridos del equipo de forma manual y automática.

3.3 ANÁLISIS DE MODOS DE FALLA

Se analizan los modos de falla presentados y el componente afectado, los cuales se muestran en la tabla 4.

Tabla 4. Análisis de falla en componentes

CÓDIGO	MODO DE FALLA	CANT	COMPONENTE
ISO 14224		FALLAS	AFECTADO
ELU	Fuga externa medio auxiliar (perdida liquido barrera)	3	SELLO MECANICO
ELP	Fuga externa médio de processo (fuga diesel)	2	
INL	Fuga interna (perdida liquido barrera)	2	
OHE	Sobrecalentamiento (sistema de sello y flushing)	3	ENFRIADORES
PDE	Desviación de parámetros (temperatura y presión)	2	
PLU	Taponamiento/Restringido (enfriadores sello)	2	
VIB	Vibración	1	RODAMIENTOS
NOI	Ruido	1	EJE
BRD	Rotura (eje)	1	IMPULSOR
UST	Parada inesperada	1	EJE o IMPULSOR

4. DESARROLLO DEL MODELO

La metodología propuesta para la detección y diagnóstico de fallas en las bombas de Diésel producto en mención en este trabajo, se basa en el uso de una red neuronal artificial (ANN), con el fin de poder detectar posibles fallas a partir de condiciones normales y anormales dadas.

El uso y aplicación de la red neuronal en este trabajo tiene dos fases; la fase de entrenamiento y la fase de pruebas.

Durante la fase de entrenamiento, la red neuronal será entrenada para comprender la relación implícita entre las entradas seleccionadas y las salidas esperadas.

Luego del entrenamiento, la red se prueba con datos de prueba para establecer si su elección, diseño y aplicación fue la más adecuada y en especial si es la herramienta adecuada para el desarrollo de este trabajo.

Una vez que las redes estén entrenados y probadas, estarán listas para detectar fallas en diferentes condiciones de funcionamiento del equipo. Con esto buscamos optimizar su ciclo de vida y realizar la oportuna toma de decisiones para realizar las actividades de mantenimiento en el equipo antes de que falle.

Estas fallas ocasionan altos costos de producción y mantenimiento y generan riesgos de afectaciones a las personas e instalaciones, afectando la confiabilidad del sistema


4.1 ETAPAS DEL DESARROLLO DEL MODELO

Durante el desarrollo del modelo para la detección y diagnóstico de fallas en las bombas de Diésel producto, deben ser considerados las siguientes etapas:

- Selección de entradas y salidas.
- Adquisición, selección y normalización de datos.
- Normalización e datos.
- Selección de la estructura y construcción de la red
- Entrenamiento y pruebas

La figura 57, muestra los pasos para el desarrollo del modelo.

Figura 57. Pasos para el desarrollo del modelo



4.1.1 Selección de variables de entrada y salida. Es muy importante seleccionar correctamente las variables de entrada y salida de la Red neuronal, ya que ellas se entrenaran de acuerdo a la relación entre estas variables proporcionadas durante la fase de entrenamiento.

Para este modelo de detección y diagnóstico de fallas basado en redes neuronales, las variables de entrada representan el estado operativo del equipo en estudio, y la salida será la condición de operación normal o anormal.

4.1.1.1 Variables de entrada Las variables de entrada pueden ir desde la operación óptima (estado óptimo o estado nuevo) hasta la operación en falla en algunos de sus componentes como se muestra en la Tabla 5, de acuerdo a las variables de operación o estado del equipo tenidas en cuenta para el diseño, entrenamiento y prueba del modelo:

Tabla 5. Variables de entrada para la red neuronal

CONDICIONES OPERACIONALES DEL EQUIPO	
1	PRESION SUCCION
2	FLUJO
3	TEMPERATURA SUCCION
4	NIVEL SUCCION
5	PRESION SELLO
6	TEMPERATURA SELLO
7	TEMPERATURA FLUSHING
8	VIBRACION BOMBA
9	VELOCIDAD MOTOR-BOMBA
10	CORRIENTE MOTOR
11	TEMPERATURA RODAMIENTOS

Estas características anteriormente listadas, pueden llegar a inducir fallas en los diferentes componentes del sistema, de los cuales, los más comunes son falla en de sistemas de sellado, falla de rodamientos, sobrecalentamiento y parada inesperada.

4.1.1.2 Variables de salida Las variables de salida que esperamos de la red, serán las que muestren el correcto o incorrecto funcionamiento del equipo que pueden causar las fallas que hasta ahora se han presentado en el equipo o por el contrario su operación óptima o esperada.

4.1.2 Adquisición, selección y normalización de datos. La generación o recopilación de los datos de entrenamiento es un paso muy importante en el desarrollo de los modelos de redes neuronales (ANN).

Para lograr un buen desempeño de la red neuronal, los datos de entrenamiento deben contener la mayor cantidad de condiciones reales de operación del sistema analizado, que en esta ocasión es una centrífuga de diésel producto.

Los datos obtenidos del equipo para el análisis y posterior entrenamiento de la red neuronal están contenidos en los anexos 3 al 7, ubicados al final del trabajo, en donde tenemos detallados los datos por cada una de las fallas evidenciadas en el equipo.

4.1.3 Normalización de datos. Los datos obtenidos del sistema analizado, son alimentados a la red como patrones de entrenamiento. Las variables de entrada son priorizadas de acuerdo a su criticidad, ya que son las más importantes y pueden llegar a opacar las variables de menor peso o criticidad.

Si los datos en total son aplicados directamente a la red, existe un riesgo de saturación, ya que las neuronas alcanzan condiciones saturadas y ocasionar un mal funcionamiento del modelo. Si las neuronas se saturan, entonces los cambios en el valor de entrada producirán un cambio muy pequeño o ningún cambio en el valor de salida y esto afecta el entrenamiento y funcionamiento de la red en gran medida.

De acuerdo a esto, los datos son normalizados antes de ser presentados a la red neuronal, de tal forma que la red sea bien entrenada para su desarrollo. Para tal fin se realizara una extracción de características de los datos para alimentar la red.

4.1.3.1 Análisis de componentes principales (PCA). Cuando se recoge la información de una muestra de datos, lo más frecuente es adquirir el mayor número de variables posibles. Sin embargo, al tomar demasiadas variables, tendremos que considerar posibles crecientes de correlación.

Estas técnicas fueron inicialmente desarrolladas por Pearson a finales del siglo XIX y posteriormente fueron estudiadas por Hotelling en los años 30. Sin embargo, solo hasta la aparición de los ordenadores no se empezaron a popularizar en las diferentes ramas de la ciencia como estadística y otras.

El PCA se emplea especialmente en análisis de datos, para construir modelos predictivos y para reducir la dimensionalidad de un grupo de datos. PCA tiene por objeto transformar o convertir un conjunto de datos, en un nuevo conjunto de valores denominadas componentes principales. Estas últimas se caracterizan por estar relacionadas entre sí y, además, pueden ordenarse de acuerdo con la información que llevan incorporada.


En PCA los primeros componentes principales describen la mayor parte de la varianza de los datos (más cuanto más correlacionadas estuvieran las variables originales). Estos componentes de bajo orden a veces contienen el aspecto "más importante" de la información, y los demás componentes se pueden ignorar. Existen diferentes técnicas para estimar el número de componentes principales que son

relevantes; la técnica más apropiada dependerá de la estructura de correlaciones en los datos originales³³. (ver figura 58)

Existen dos formas básicas de aplicar el ACP:

1. Método basado en la matriz de correlación, cuando los datos no son dimensionalmente homogéneos o el orden de magnitud de las variables aleatorias medidas no es el mismo.
2. Método basado en la matriz de covarianzas, que se usa cuando los datos son dimensionalmente homogéneos y presentan valores medios similares.

Figura 58. Ejemplo de Análisis de componentes principales.



Fuente: WIKIPEDIA Análisis de componentes principales [en línea] disponible en:
https://es.wikipedia.org/wiki/An%C3%A1lisis_de_componentes_principales

La aplicación de PCA está limitada varios algunos aspectos como:


³³ Peres-Neto, Pedro R.; Jackson, Donald A.; Somers, Keith M. «How many principal components? stopping rules for determining the number of non-trivial axes revisited». Computational Statistics & Data Analysis 49 .

Suposición de linealidad: Se asume que los datos analizados son combinación lineal de una cierta base de datos.

Importancia estadística de la media y la covarianza: PCA utiliza los vectores propios de la matriz de covarianzas y sólo establece las direcciones de los ejes en el espacio de variables considerando que los datos se distribuyen de manera gaussiana.

4.1.3.2 Árbol de decisión (Decisión tres). Un árbol de decisión, es un modelo de predicción usado en diversos ámbitos como la inteligencia artificial, economía entre otras. A partir de un conjunto de datos se fabrican diagramas de construcciones lógicas, muy similares a los sistemas de predicción basados en reglas, que sirven para representar y categorizar una serie de condiciones que ocurren de forma sucesiva, para la resolución de un problema. (ver figura 59)

Figura 59. Estructura de un árbol de decisión.



Fuente: MONOGRAFÍAS Análisis sensibilidad arboles decisión punto equilibrio [en línea] disponible en: www.monografias.com/trabajos105/analisis-sensibilidad-arboles-decision-puntoequilibrio/analisis-sensibilidad-arboles-decision-puntoequilibrio.shtml


Es un método comúnmente usado en la ciencia de la minería de datos y una herramienta de modelado predictivo muy ampliamente usada en estadísticas, minería de datos y aprendizaje automático, en donde la variable objetivo puede tomar un conjunto finito de valores que se denominan árboles de clasificación. El objetivo principal es crear un modelo que predice el valor de una variable de destino en función de diversas variables de entrada.

El aprendizaje basado en árboles de decisión es una técnica muy eficaz para la clasificación supervisada y se puede usar en conjunto con otras herramientas para la detección y diagnóstico de fallas. Puede ser "aprendido" mediante el fraccionamiento del conjunto inicial en subconjuntos basados en una prueba de valor de atributo.

En la minería de datos, los árboles de decisión se pueden describir también como la combinación de técnicas matemáticas y computacionales para ayudar a la descripción, la categorización y la generalización de un grupo de datos.

Un ejemplo de árbol de decisión se puede aplicar para determinar el tipo de mantenimiento a aplicar en un equipo, como se muestra en la figura 60.

Figura 60. Árbol de decisión en Mantenimiento.



Fuente: SLIDE SHARE Mantenimiento industrial [en línea] disponible en: www.es.slideshare.net/guionbajho/mantenimiento-industrial

4.1.4 Selección de la estructura de la red. Para elaborar una red neuronal con el fin de que esta realice una tarea específica (deseada), se debe elegir el número de neuronas de entrada, las neuronas de salida y las neuronas ocultas para obtener un mejor rendimiento de la red.

El número adecuado de capas ocultas se puede determinar usando un procedimiento de prueba y error con el fin de conocer cuál es el número más adecuado de capas, en donde la red se desempeña de mejor manera.

Las neuronas de capa oculta pueden tener como función de activación la función hiperbólica tangente y las neuronas de salida tienen una función de activación lineal.


Una vez que se selecciona adecuadamente la estructura de la red, se entrena el modelo con los datos recopilados, con el fin de establecer o hallar la relación oculta

entre los valores de entrada y salida de la red. Esto se hace utilizando los datos de entrenamiento adquiridos el equipo.

4.1.4.1. Perceptron multicapa La estructura de red neuronal seleccionada para este trabajo es la Red Perceptron Multicapa, (ver figura 61) por ser una de las más efectivas y aplicadas en este tipo de modelos, sin embargo se probaran otros modelos para revisar su eficacia.

Un Perceptrón multicapa es una red con alimentación hacia delante, compuesta de varias capas de neuronas entre la entrada y la salida de la misma. Este tipo de red consiste en una serie de capas, la primera capa tiene una conexión con la capa de entrada y cada una de las capas subsecuentes tiene conexión con la capa previa. La capa final produce la salida de la red neuronal.

Figura 61. Red neuronal Feedforward.



Fuente: HAGAN, Martin y otros Neural network design.

Logartimo back propagation.

Este tipo de red es entrenada por medio del algoritmo back **propagation**, el cual calcula los gradientes locales de cada neurona y gradualmente va ajustando sus pesos y byas para minimizar el error cuadrático. Es un método de cálculo del

gradiente utilizado en algoritmos de aprendizaje supervisado utilizados para entrenar redes neuronales artificiales.

Este algoritmo propaga el error desde la capa de salida a la capa oculta para actualizar la matriz de peso. Después del entrenamiento, las redes se prueban con el conjunto de datos de prueba para evaluar la capacidad de predicción de la red desarrollada.

El método emplea un ciclo propagación – adaptación de dos fases. Una vez que se ha aplicado un patrón a la entrada de la red como estímulo, este se propaga desde la primera capa a través de las capas siguientes de la red, hasta generar una salida. La señal de salida se compara con la salida deseada y se calcula una señal de error para cada una de las salidas. Las salidas de error se propagan hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de la capa oculta que contribuyen directamente a la salida. Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido una señal de error que describa su contribución relativa al error total.

La importancia de este proceso consiste en que, a medida que se entrena la red, las neuronas de las capas intermedias se organizan a sí mismas de tal modo que las distintas neuronas aprenden a reconocer distintas características.

Después del entrenamiento, cuando se les presente un patrón arbitrario de entrada que contenga ruido o que esté incompleto, las neuronas de la capa oculta de la red responderán con una salida activa si la nueva entrada contiene un patrón que se asemeje a aquella característica que las neuronas individuales hayan aprendido a reconocer durante su entrenamiento.


4.1.5 Entrenamiento y pruebas A continuación describimos el proceso de extracción de características, análisis de componentes principales, el desarrollo de

la red neuronal, su entrenamiento, validación y seguimiento de los resultados obtenidos.

4.1.5.1 Extracción de características Utilizando el análisis de principales componentes (PCA) se realiza una exploración de los datos en su conjunto para evaluar la descomposición de sus valores propios y determinar las componentes más significativas de impacto en los datos experimentales existentes.


Inicialmente se realiza un análisis de distribución de las variabilidad de los datos suministrado, la figura 62 muestra que las características que tienen mayor variabilidad entre ellas son la temperatura en la succión, temperatura de Flushing lado Acople y lado empuje, nivel, y flujo de la bomba (BPD). Por lo cual el análisis de principales componentes sería acertado aplicarse para establecer cuales componente representan el 95% de todos los datos.

Figura 62. Distribución de todos los Datos de Falla en las Bombas.




4.1.5.2 Análisis de Principales Componentes. La figura 63 presenta el análisis de impacto de las componentes principales (PCA) en todo el espectro de los datos disponibles históricos de tres años de la planta.

Figura 63. Análisis de Principales Componentes




La figura 64 muestra las 10 principales componentes que explican el 75% del comportamiento de los datos respecto a los modos de fallos expuestos anteriormente.

Figura 64. Principales componentes



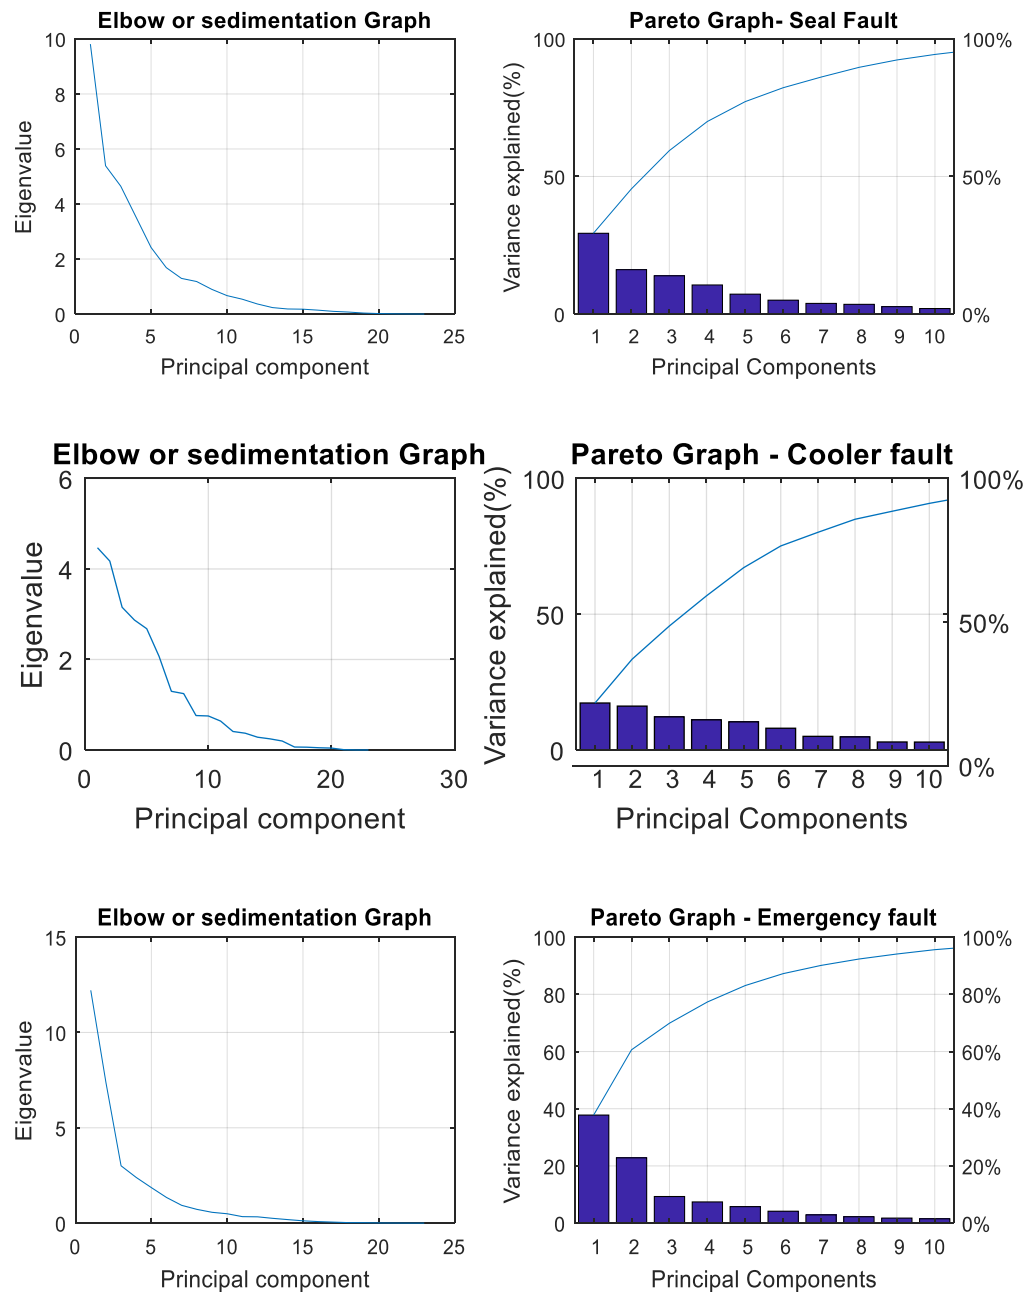
La figura 65 explica el comportamiento de las características que más impactan las dos principales componentes de todos los datos. Los valores propios de la descomposición singular de los valores propios están sobre las características de temperatura de la Bomba Lado Acople, temperatura de la Bomba lado empuje y temperatura del Motor lado Acople.

Figura 65. Comportamiento de las características




Las siguientes graficas (figura 66) muestran la composición particular PCA de cada modo de falla de las bombas. Se asume tomar hasta los 10 componente principales y aplicarle una estructura de red neuronal multicapa (MLP) para reconocimiento de patrones de cada modo de falla.

Figura 66. Composición particular PCA de cada modo de falla




La figura 67 muestra la extracción de las características reducidas y la clasificación realizada por PCA, donde se muestra claramente las dos principales componentes, con lo cual se puede agrupar y clasificar definitivamente los modos de fallas.

Figura 67. Extracción de las características reducidas y la clasificación realizada por PCA



La siguiente figura 68 muestra las tres principales componentes en el espacio tridimensional, plenamente clasificadas. Usando esta reducción del espacio se aplican como entradas a la red neuronal. Al estar bien definida la clasificación de los modos de falla, facilitara enormemente el reconocimiento de los patrones de falla de Bombas.

Figura 68. Principales componentes en el espacio tridimensional



4.1.5.3 Diseño de red neuronal Multicapas de tipo perceptron Se estudian cinco clases de red neuronal para el análisis de falla de estos equipos. La primera clase representa bomba en estado de óptima condición, la cual representa condición base de referencia, son 350 datos con 23 características diferentes, los cuales son históricos de tres años de operación en de los equipos en la Refinería de Ecopetrol.

La representación para esta condición es $T1 = [1 \ 0 \ 0 \ 0 \ 0]^T$

Al azar se toman 10 datos para validación y verificación de prueba, una vez se entrene la red.

La siguiente clase representa la Falla en Rodamientos de las Bombas y es representada por $T2 = [0 \ 1 \ 0 \ 0 \ 0]^T$ con 100 datos históricos, y se dejan para validación 10 datos.

La siguiente clase representa la Falla en los sellos (Seal Fault) de la Bomba y es representada por $T3 = [0 \ 0 \ 1 \ 0 \ 0]^T$ con 100 datos históricos, y se dejan para validación 5 datos.

La siguiente clase representa la Falla en el sistema de enfriamiento (Cooler Fault) de las Bombas y es representada por $T4 = [0 \ 0 \ 0 \ 1 \ 0]^T$ con 100 datos históricos, y se dejan para validación 5 datos.

La siguiente clase representa la Falla de parada de emergencia (Emergency Fault) de las Bombas y es representada por $T5 = [0 \ 0 \ 0 \ 0 \ 1]^T$ con 100 datos históricos, y se dejan para validación 5 datos.

Cabe notar que la parada de emergencia puede ser producto de varios modos combinados y se necesitara mayor investigación para detectar y reconocer los modos base que excitan la parada de emergencia, pero esto necesitara mayor investigación que en este momento supera el alcance de esta tesis.


Los resultados de entrenamiento de la red neuronal con todos los datos procesados del PCA y los diferentes cinco clases de operación se aplican a la red MPL con 25 perceptrones en su capa escondida, y cinco al final para su respuesta.

Los prototipos de entradas son las 23 características disponibles por cada caso de Bomba, como lo muestra la tabla 6 y la figura 69.

Tabla 6. Datos de entrenamiento de la red neuronal.

ESTADO EQUIPO	REPRESENTACION	DATOS HISTORICOS	VARIABLES	DATOS VALIDACION
Optima condicion	$T1 = [1\ 0\ 0\ 0\ 0]\ T$	350	23	10
Falla rodamientos	$T2 = [0\ 1\ 0\ 0\ 0]\ T$	100	23	10
Falla de sellos	$T3 = [0\ 0\ 1\ 0\ 0]\ T$	100	23	5
Falla enfriadores	$T4 = [0\ 0\ 0\ 1\ 0]\ T$	100	23	5
Parada emergencia	$T5 = [0\ 0\ 0\ 0\ 1]\ T$	100	23	5

Figura 69. Diseño de red neuronal Multicapas de tipo perceptron



En 69 iteraciones converge la fase de entrenamiento, con indicador de $1.22 \text{ E-}07$ residual.

A continuación en la figura 70, se muestra el desempeño de la red para clasificar correctamente los modos de falla.

Figura 70. Desempeño de la red para clasificar correctamente los modos de falla


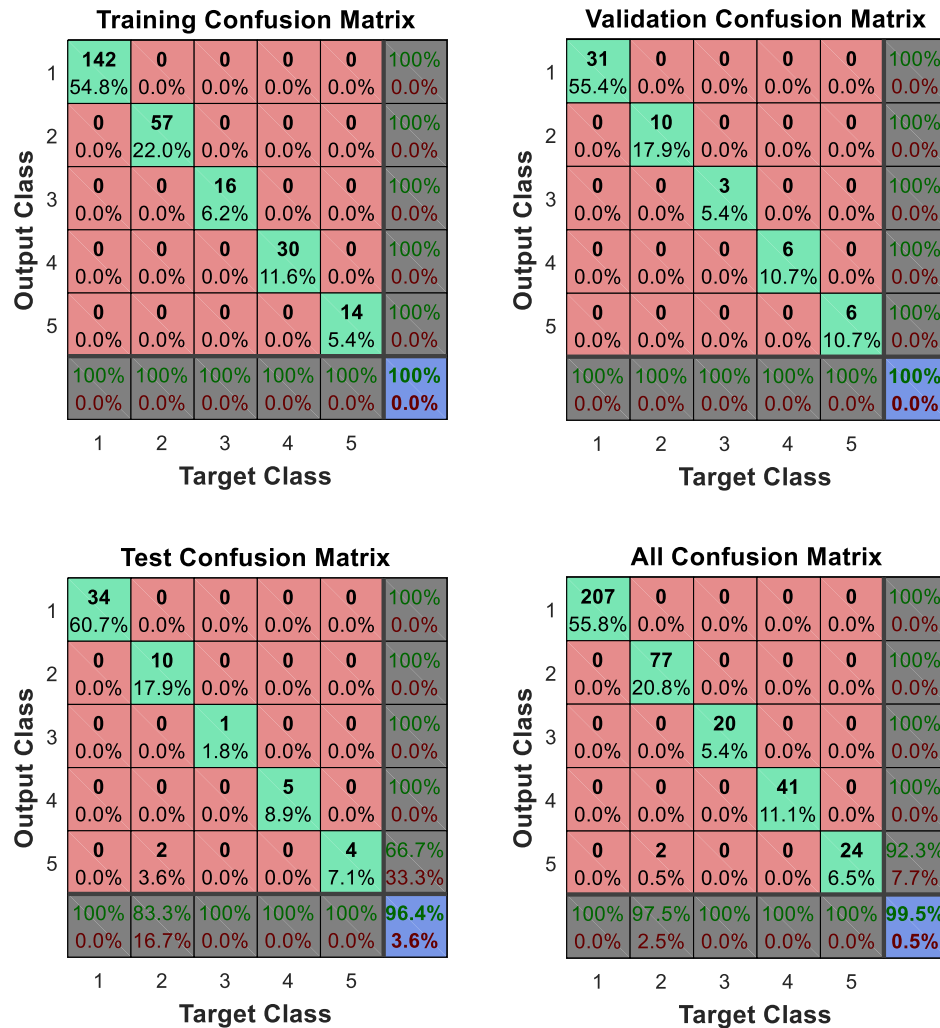



Figura 71. Matriz de confusión



La matriz de confusión que muestra la figura 71, indica la precisión con que se detectan correctamente los modos de falla, con un 99.5% de eficiencia en la detección correcta de todos los casos.

Otra Red MPL con menos perceptrones, 10 perceptrones en la capa escondida, también muestra un desempeño del orden del 96%, como se muestra en las figuras 72 al 75.

Figura 72. Datos de red neuronal.






Figura 73. Análisis de datos




Figura 74. Análisis de datos de la red neuronal






Figura 75. Análisis de datos de entrenamiento de la red



4.1.5.4 Validación de resultados con conjunto de pruebas que nunca fueron usados para entrenar y se usan para validar Para el caso de funcionamiento óptimo se dejaron 10 casos randómicos pertenecientes al caso de bomba en buena condición. El resultado una vez entrenada la red neuronal Multilayer perceptron se muestra exitosamente el reconocimiento de patrones. Ver figura 76 al 78.

Para cada caso es muy exitoso el reconocimiento de patrones de falla.

Figura 76. Validación de resultados





Figura 77. Validación de resultados



Figura 78. Validación de resultados



5. PLANES DE GESTIÓN

Para minimizar la ocurrencia de nuevas fallas en los componentes analizados del equipo, se establece el siguiente plan de gestión de mantenimiento encaminado a asegurar la confiabilidad, mantenibilidad y disponibilidad del sistema.

Las tareas planteadas tienen diferentes frecuencias de intervención por condición quincenal, mensual, trimestral, semestral y quinquenal.

5.1 FALLA DE SELLO MECÁNICO

Se establecen las siguientes actividades preventivas y por condición, con el fin de minimizar las fallas en los sistemas de sellos mecánicos plan API 53B, y con esto prevenir las fugas internas y externas de medio auxiliar y de fluido de proceso, como se muestra en la tabla 7.

Dependiendo de la actividad a realizar, se debe sacar de servicio el equipo, para que la actividad se realice de manera segura y confiable.

Tabla 7. Plan de gestión de Mantenimiento para falla de sistema de sellos mecánicos.

CODIGO ISO 14224	MODOS DE FALLA	COMPONENTE AFECTADO	ESTRATEGIA	TAREA	FRECUENCIA	ALCANCE	EJECUTOR
ELU	Fuga externa medio auxiliar (perdida liquido barrera)	SELLO MECANICO	Preventiva	Ajuste presion liquido barrera	Por condicion	Ajuste presion liquido barrera con sistema hidraulico	Operador del area
ELP	Fuga externa medio de proceso (fuga diesel)			Ajuste presion N2 vejiga	Trimestral	Verificar y/o Ajustar presion de N2 en la vejiga	Mantenimiento
INL	Fuga interna (perdida liquido barrera)			Cambio total liquido barrera	Semestral	Drenar y cambiar liquido barrera	Mantenimiento
			Por condicion	Reparacion general del sello	Por condicion	Mantenimiento de sellos en taller	Mantenimiento

5.1.1 Ajuste de presión de líquido barrera Se utiliza bomba hidráulica para reponer presión en el sistema de sello de los equipos, para garantizar su buen funcionamiento y evitar el daño del mismo y fugas externas de fluido de proceso. Se debe asegurar que el líquido barrera esté libre de agua, sea de las características correctas y se ajuste a la presión de diseño del sistema. Esta actividad es realizada por el Operador del equipo, como se muestra en la figura 79.

Figura 79. Ajuste de presión de líquido barrera.



5.1.2 Ajuste de presión de N2 en la vejiga Para ajustar esta presión, Personal de Mantenimiento instala accesorio para ajustar presión de la vejiga del sistema de sello con Nitrógeno gaseoso (N2) a la presión adecuada. Se han tenido casos en donde la vejiga se encuentra rota y la presión se pierde rápidamente, por lo cual se hace necesario el cambio de la vejiga.

Para los casos de ajuste de presión de líquido barrera y presión de N2 en la vejiga del sistema de sello plan API 53B, se tienen estipulados los siguientes valores para tener en cuenta en las actividades de mantenimiento del sistema, como se muestra en la figura 80 y tabla 8.

Figura 80. Ajuste de presión de N2 en acumulador de sistema de sello.



Tabla 8. Valores de ajuste de presión de sistema de sellos.

CONDICIONES DE OPERACIÓN SELLOS MECANICOS			
TAG	SP-4704 A/B	PLAN DE SELLO	21 - 53B
PRESION DE TRABAJO	125 PSI	FLUIDO BARRERA	MOBIL SYNTURION 6
SET ALARMA (L)	115 PSI	PRECARGA VEJIGA	75 PSI
SET ALARMA (LL)	105 PSI	FECHA ACTUALIZACION	OCTUBRE 2018

5.1.3 Cambio de líquido barrera Se debe realizar el cambio total de líquido barrera por degradación de mismo debida a las altas temperaturas de operación o también por la contaminación con fluido de proceso, en especial por la formación de partículas de carbón, las cuales pueden llegar a ocasionar daños en el sistema de sello.

Para esta actividad se debe drenar completamente el líquido existente y se debe reemplazar con líquido barrera nuevo, el cual debe estar limpio y libre de agua. El tipo de líquido barrera se aplica según recomendación del fabricante del sistema de sello de acuerdo a las características de operación del equipo, como se muestra en la figura 81.

Figura 81. Cambio de líquido barrera.



5.1.4 Reparación de sello mecánico Para la reparación del sello mecánico del equipo, este se debe retirar del equipo fuera de servicio y se lleva al taller de sellos, para realizar su mantenimiento general, el cual incluye cambio de orings, resortes, caras de los sellos, camisas y las demás partes que se consideren en mal estado.

La instalación del sistema de sello en el equipo es también relevante en esta tarea de mantenimiento, debido a que el procedimiento de transporte e instalación del mismo es de gran cuidado, ya que allí se puede dañar el sistema de sellos. (ver figura 82).

Figura 82. Reparación de sello mecánico.



5.2 FALLA DE ENFRIADORES

Se establecen las siguientes actividades para asegurar la confiabilidad de los sistemas de enfriamiento de los sistemas de sello y flushing del equipo, dado que la temperatura en estos sistemas afecta notablemente la vida útil de los sistemas de sello. (ver tabla 9).

Tabla 9. Plan de gestión de Mantenimiento para falla de Enfriadores de sistema de sellos mecánicos.

CODIGO ISO 14224	MODO DE FALLA	COMPONENTE AFECTADO	ESTRATEGIA	TAREA	FRECUENCIA	ALCANCE	EJECUTOR
OHE	Sobrecalentamiento (sistema de sello y flushing)	ENFRIADORES SISTEMA DE SELLO Y FLUSHING	Preventiva	Retrolavado del enfriador	Mensual	Realizar retrolavado a enfriadores	Operador del area
PDE	Desviacion deparámetros (temperatura y presion)			Limpieza mecanica	Trimestral	Realizar limpieza con hidrojet	Mantenimiento
PLU	Taponamiento/Restringido (enfriadores sello)			Prueba hidrostatica	Trimestral	Realizar prueba hidrostatica para descartar daños en material	Mantenimiento
			Por condicion	Cambio total del serpentín	Por condicion	Reemplazar serpentín por daño	Mantenimiento

5.2.1 Retrolavado de enfriadores Esta actividad es realizada por el Operador del equipo y se hace mediante circulación del agua de enfriamiento en sentido contrario,

con el fin de limpiar las áreas de transferencia de calor dentro del enfriador. Esta actividad no es tan efectiva como una limpieza mecánica, sin embargo mejora considerablemente el enfriamiento de los sistemas de sello y flushing. (ver figura 83).

Figura 83. Retrolavado de enfriadores



5.2.2 Limpieza mecánica de enfriadores Cuando la limpieza por medio de retrolavados ya no es efectiva y no se evidencian cambios en el sistema de enfriamiento de sello y flushing, se deben destapar los enfriadores con el equipo fuera de servicio y realizar una limpieza mecánica con la ayuda de espátulas, cepillos desengrasante y lavado con agua por medio de maquina hidrojet, como se muestra en la figura 84.

Figura 84. Limpieza mecánica de enfriadores.



5.2.3 Prueba hidrostática Además de la tarea de limpieza mecánica de los enfriadores, se debe realizar una prueba hidrostática (ver figura 85) a la presión de diseño estipulada por el fabricante, con el fin de detectar grietas o daños en la metalurgia de los enfriadores, lo cual afecte la transferencia de calor, la contaminación del líquido barrera con agua o viceversa o la pérdida de presión de líquido barrera.

Figura 85. Prueba hidrostática a serpentín.




5.2.4 Cambio del serpentín del enfriador Cuando se detecta falla mecánica en el serpentín sea cual sea el método de detección, este debe ser reemplazado para asegurar la confiabilidad del equipo y la seguridad de los sistemas. Este se debe

Tabla 10. Plan de gestión de Mantenimiento para falla de rodamientos, eje e impulsor.

CODIGO ISO 14224	MODO DE FALLA	COMPONENTE AFECTADO	ESTRATEGIA	TAREA	FRECUENCIA	ALCANCE	EJECUTOR		
VIB	Vibracion	RODAMIENTOS EJE IMPULSOR	Preventiva	Monitoreo vibraciones	Quincenal	Realizar monitoreo con CSI	Operador		
NOI	Ruido			Analisis/Cambio de aceite		Realizar chequeo de estado de aceite. Enviar muestra para analisis Cambiar según condicion	Operador		
BRD	Rotura (eje)				Alineacion conjunto motor-bomba	Semestral	Verificar / Ajustar alineacion con laser	Mantenimiento	
					Termografias	Semestral	Realizar termografias a rodamientos del motor y bomba	Mantenimiento	
			Por condicion	Cambio de rodamientos	Por condicion	Reemplazo de rodamientos	Mantenimiento		
				Cambio eje		Reemplazo del eje, balanceo y alineacion del conjunto	Mantenimiento		


5.3.1 Monitoreo de vibraciones Se realiza monitoreo de vibraciones en tiempo real en el sistema de monitoreo de vibraciones del equipos y se realizara una ronda por parte del Operador y supervisada por el Ingeniero de Confiabilidad para detectar cualquier indicio de fallas en estos componentes, de acuerdo a la figura 87.

Figura 87. Monitoreo de vibraciones.



5.3.2 Termografías Realizar termografías a rodamientos del motor y bomba, para identificar puntos calientes o indicio de fallas en los rodamientos, como se muestra en la figura 88.

Figura 88. Termografía a rodamientos



5.3.3 Análisis / Cambio de aceites lubricantes El análisis del estado del aceite y el funcionamiento del sistema de lubricación del equipo, hace parte de una ronda de verificación diaria del Personal operativo. Además de esta ronda se realizara un análisis básico del estado del aceite y la toma de una muestra para enviar a análisis de laboratorio, en donde con procedimientos más exhaustivos se determina el estado real del aceite, incluyendo presencia de partículas extrañas, agua, metales, análisis de viscosidad, entre otros, con los cuales podemos determinar la salud del equipo y donde podremos tomar decisiones para actividades de mantenimiento del equipo. (ver figuras 89 y 90).

Figura 89. Revisión de aceite de lubricación.





Figura 90. Análisis de laboratorio de aceite de lubricación.



5.3.4 Alineación de conjunto motor bomba Como medida preventiva o ante cualquier indicio de vibraciones mecánicas en el equipo, debidas a desalineamiento,

se establece una rutina para verificación del mismo. Al final el alineamiento del equipo debe quedar dentro de los valores tolerables, a fin de evitar las vibraciones mencionadas. Se tiene en cuenta que este equipo opera a condiciones extremas de temperatura y flujo, lo que lo hace muy sensible a presentar síntomas por desalineamiento, como se muestra en la figura 91.

Figura 91. Alineación conjunto motor bomba.



Fuente: www.skf.com

5.3.5 Cambio del eje. En caso de presentarse falla del eje por fractura, ralladura o fuerte deflexión, se requerirá su reemplazo 1 a 1, según especificaciones del fabricante. Cuando se realice este cambio es necesario realizar un balance del eje en conjunto con el impulsor, como se muestra en la figura 92.

Figura 92. Fabricación eje bomba centrífuga.



5.3.6 Cambio de rodamientos Dependiendo de la condición de los rodamientos del equipo o si se evidencian vibraciones asociadas a este tipo de falla se programa

cambio de rodamientos por condición o si por oportunidad lo requiere. (ver figura 93)

Figura 93. Cambio de rodamientos bomba centrífuga.



5.4 FALLA POR PARADA INESPERADA

Para evitar fallas del equipo por parada inesperada, lo cual afecta gravemente el proceso de la planta y los costos de mantenimiento y la confiabilidad del equipo, se establecen varias tareas, como se muestra en la tabla 11. Algunas de estas tareas son las mismas para el caso de falla del equipo por falla de rodamientos y falla de

eje o impulsor, en donde se establecen tareas de cambio de rodamientos por condición, monitoreo de vibraciones de forma preventiva y análisis de aceite de lubricación.


Tabla 11. Plan de gestión de Mantenimiento para falla de parada inesperada.

CODIGO ISO 14224	MODOS DE FALLA	COMPONENTE AFECTADO	ESTRATEGIA	TAREA	FRECUENCIA	ALCANCE	EJECUTOR
UST	Parada inesperada	EJE o IMPULSOR	Por condicion	Cambio de rodamientos	Por condicion	Cambio de rodamientos por falla	Mantenimiento
			Preventiva	Monitoreo vibraciones	Quincenal	Realizar monitoreo con CSI	Operador
		MOTOR	Preventiva	Monitoreo vibraciones	Quincenal	Realizar monitoreo con CSI	Operador
				Análisis/Cambio de aceite	Quincenal	Realizar chequeo de estado de aceite. Enviar muestra para análisis Cambiar según condición	Operador
				Pruebas eléctricas	Semestral	Pruebas eléctricas al motor (Aislamiento, TTR)	Mantenimiento
			Preventiva	Mantenimiento General	Quinquenal	Mantenimiento general en taller	Mantenimiento

El motor eléctrico aunque no ha presentado fallas, también merece un ser incluido dentro de este plan, debido a que es un equipo de alta potencia.

5.4.1 Pruebas eléctricas Se realizan tareas de megueo y pruebas de índice de polaridad de los devanados, como se muestra en la figura 94, a fin de mantener su confiabilidad.

Figura 94. Pruebas eléctricas al motor.



5.4.2 Mantenimiento general del motor Debido al tamaño del equipo se hace necesario llevar este motor a un taller especializado, para recuperar su confiabilidad con tareas de limpieza, cambio de chumaceras, secado en horno y barnizado de los devanados, como se muestra en la figura 95.

Figura 95. Actividades de mantenimiento general del motor.



6. CONCLUSIONES

El uso de técnicas avanzadas de mantenimiento permite a los Ingenieros de mantenimiento la anticipación a fallas y la optimización de los proceso de Operación y Mantenimiento, obteniendo beneficios que repuntan en rentabilidad de las empresas.

El uso de las Redes Neuronales Artificiales en la predicción y detección de fallas en equipos industriales ha mostrado buenos resultados, siendo una de las herramientas más usadas en la materia de técnicas avanzadas de mantenimiento, lo cual ha permitido crear programas aplicables a la industria.

Para el desarrollo del modelo fueron analizados los modos de falla presentados en el equipo en estudio, estableciendo cuales son los más frecuentes y los que más impactan en sus costos de mantenimiento, siendo la falla de sistemas de sellado y falla de rodamientos los que más impactan.

Se revisaron las arquitecturas aplicables a este modelo, utilizando la MLP por ser una de las más efectivas para este tipo de modelos de reconocimiento de patrones para detección y diagnóstico de fallas.

Fue adquirida información de 23 variables de operación del equipo analizado, con una muestra de 25.000 datos en un periodo de 36 meses.

Se realizó una extracción de características con PCA para normalizar los datos y poder entrenar la red.

La extracción de las características reducidas y la clasificación realizada por PCA, muestra claramente las principales componentes, con lo cual se puede agrupar y clasificar definitivamente los modos de fallas mencionados.

Para el modo de falla de parada de emergencia se deduce que puede ser producto de varios modos combinados y se necesitara mayor investigación para detectar y reconocer los modos base que excitan la parada de emergencia.

Los resultados de entrenamiento de la red neuronal con todos los datos procesados del PCA y los diferentes cinco clases de operación se aplican a la red MLP con 25 perceptrones en su capa escondida, y cinco al final para su respuesta.

Se estudian 5 redes neuronales en Matlab para el análisis de falla de los equipos usando 350/100 datos con 23 características y se dejan para validación 10 datos.

La matriz de confusión de la red muestra una precisión con la que se detectan correctamente los modos de falla, con un 99.5% de eficiencia en la detección correcta de todos los casos. Otra Red MLP con menos perceptrones, 10 perceptrones en la capa escondida, también muestra un desempeño del orden del 96%. El resultado una vez entrenada la red neuronal Multilayer perceptron, muestra exitosamente el reconocimiento de patrones de falla.

El uso de las Redes Neuronales Artificiales en la predicción y detección de fallas ha mostrado buenos resultados, siendo una de las herramientas más usadas como técnica avanzada de mantenimiento. El uso de este tipo de herramientas, nos permite tener un panorama más amplio de cómo aplicar el mantenimiento, gracias a estas técnicas, es viable predecir fallas y optimizar los procesos.

Después de haber elaborado y probado el modelo en el equipo analizado, se ve viable poderlo aplicar a otra familia de equipos en los cuales queramos optimizar su ciclo de vida.

Es necesario ajustar y crear nuevas rutinas de mantenimiento en el equipo analizado, con el fin de asegurar la confiabilidad y disponibilidad, por lo que se estructuran los planes de gestión para el mantenimiento de los equipos en estudio.

Durante la aplicación de estas rutinas de mantenimiento se prevé que los costos de mantenimiento asociados al equipo estén dentro de lo estipulado anualmente. Así mismo recuperar los indicadores de MTBF y MTBR del equipo, para lograr que sea un equipo más confiable.

BIBLIOGRAFÍA

ARANGUREN, Sandra. Metodologías y tecnologías de detección y diagnóstico de fallas aplicadas a procesos Industriales. Revista Colombiana de Tecnologías de Avanzada 2009.

BORRAS Carlos. Técnicas avanzadas de Mantenimiento. UIS, 2016

BORRAS PINILLA, Carlos. Pattern recognition in hydraulic cylinders with blackwash using neural network. Testis de Maestro. Oklahoma: University of Oklahoma. School of Aerospace and Mechanical Engineering, 2001, 113p.

DIAZ, Fabián. Detección de fallas en bombas usando SVM. Tesis de Maestría, Bucaramanga: Universidad Industrial de Santander. 2017 28 p.

Gestión de activos físicos", Apuntes para el curso ME 5701, Departamento de Ingeniería Mecánica, Universidad de Chile.

GOOGLE Unidad 4 redes neuronales [en línea] [citado el: 01 de diciembre de 2018]. Disponible en: www://sites.google.com/site/mayinteligenciartificial/unidad-4-redes-neuronales

HAGAN, Martin y otros. Neural network design, tomo 20. PWS publishing company. Boston, 1996.

HURTADO Y VILLAREAL. Fault detection and diagnosis through artificial intelligence techniques, a state of art. Facultad Tecnológica, Universidad Distrital Francisco José de Caldas, Bogotá, Colombia. 2016

ISERMANN. Model-based fault-detection and diagnosis – status and applications. Institute of Automatic Control, Darmstadt University of Technology, Germany. 2004

KARDEK, A, NASCIF, J. Mantenimiento, Función Estratégica, CIP Brasil, Rio de Janeiro, 2002

LAFFRAIA, J. R Manual de confiabilidad, Mantenibilidad e disponibilidad, Qualitymark Editora, 2001.

MARADEY, Jessica. Diagnóstico de fallas en bombas hidráulicas de Pistones axiales, aplicando Redes Neuronales (ANN´S). Tesis Universidad Industrial de Santander, 2017

MATICH, Damián. Redes Neuronales: Conceptos Básicos y Aplicaciones. Universidad Tecnológica Nacional – Facultad Regional Rosario Departamento de Ingeniería. 2001. 8p.

MESA GRAJALES, Dairo H., ORTIZ SÁNCHEZ, Yesid, PINZÓN, Manuel, La confiabilidad, la disponibilidad y la mantenibilidad, disciplinas modernas aplicadas al mantenimiento. Scientia Et Technica [en línea] 2006, XII

MINITAB What is a failure mode [en línea] disponible en: <https://support.minitab.com/es-mx/minitab/18/help-and-how-to/modeling-statistics/reliability/supporting-topics/basics/what-is-a-failure-mode/>

MOYA, Jorge y otros. Utilización de Sistemas Basados en Reglas y en Casos para diseñar transmisiones por tornillo sinfín. Universidad Autónoma de Zacatecas y Universidad Central Cuba, Facultad de Ingeniería Mecánica, 2011

PERES, Pedro R.; Jackson, Donald A.; Somers, Keith M. «How many principal components? stopping rules for determining the number of non-trivial axes revisited». Computational Statistics & Data Analysis 49.

PEREZ, Hugo. Modelo para análisis de Riesgo en las bombas del sistema de enfriamiento mediante el uso de Redes Neuronales. Tesis Universidad Industrial de Santander, 2017

QUISPE, Nelson. Redes Neuronales Artificiales, Metodología de Desarrollo y Aplicaciones. [en línea] Disponible en: <https://www.monografias.com/trabajos95/redes-neuronales-artificiales-metodologia-desarrollo-y-aplicaciones/redes-neuronales-artificiales-metodologia-desarrollo-y-aplicaciones.shtml>

RAJAKARUNAKARAN, DEVARAJ Y SURYAPRAKASA. Artificial neural network approach for fault detection in rotary system. A.K College of Engineering, Department of Industrial Engineering, Anna University, Tamilnadu, India, 2007

ROLF Iserman. Fault diagnostica systems. Springer Verlag London, 2006.

VARGAS, William. “Elaborar un modelo de gestión de Confiabilidad en mantenimiento, basado en supervisión automática y control operativo para las bombas centrifugas para las Planta de Hidrotratamiento de la GRB” Trabajo de grado en maestría. UIS. 2017. 37 p.

ANEXOS

Anexo A. Datasheet Bomba de Diésel Producto.

Pump Data Sheet - Sulzer Pumps Ltd.

Company: Sulzer Pumps (US) Inc.
Name: TECHNIP ITALY - ECOPEXROL
Date: 3/29/2007

P-4704 A/B - HEAVY DIESEL PRODUCT PUMPS

Powered By
PUMP-FLO®

Pump:

Size: 10x12x27G-1
Type: BBS
Synch speed: 1800 rpm
Curve: BBS 43-1-3-01
Specific Speeds:
Dimensions:
Vertical Turbine:

Speed: 1780 rpm
Dia: 22.44 in
Impeller:
Ns: 850
Nss: 10950
Suction: 12 in
Discharge: 10 in
Bowl size: --- in
Max lateral: 1.10204e-038 in
Thrust K factor: ---

Search Criteria:

Flow: 3921 US gpm
Head: 473 ft
Preferred Operating Region: 80% to 110% of BEP
Secondary Operating Point: 3439 US gpm, 473 ft
Max suction specific speed: 11000 (Nss)

Fluid:


HC DIESEL PRODUCT
SG: 0.66
Viscosity: 0.19 cP
NPSHa: 19 ft
Temperature: 607.2 °F
Vapor pressure: 26.3 psi a
Atm pressure: 14.7 psi a

Motor:

Consult Sulzer Pumps Ltd. to select a motor for this pump.

Pump Limits:

Temperature: 800 °F
Pressure: 600 psi g
Sphere size: 0.93 in
Power: 3473 hp
Eye area: --- in²



Performance Evaluation:					
Flow US gpm	Speed rpm	Head ft	Efficiency %	Power hp	NPSHr ft
4705	1780	---	---	---	---
3921	1780	473	73.9	419	12.3
3137	1780	514	71.7	374	10.4
2353	1780	540	66.3	318	10.1
1568	1780	555	57.1	258	10.2

Anexo B. Hoja de seguridad Diésel.

DIESEL, No. 2		ICSC: 1561
DATOS IMPORTANTES		
ESTADO FÍSICO; ASPECTO: Líquido marrón, ligeramente viscoso, de olor característico.		VÍAS DE EXPOSICIÓN: La sustancia se puede absorber por inhalación del aerosol.
LÍMITES DE EXPOSICIÓN: TLV: 100 ppm como TWA; (piel); A3 (cancerígeno animal); (ACGIH 2004).		RIESGO DE INHALACIÓN: Por evaporación de esta sustancia a 20 °C no se alcanza, o se alcanza sólo muy lentamente, una concentración nociva en el aire.
		EFFECTOS DE EXPOSICIÓN DE CORTA DURACIÓN: La sustancia irrita los ojos, la piel y el tracto respiratorio. La sustancia puede afectar al sistema nervioso central. La ingestión del líquido puede dar lugar a la aspiración del mismo por los pulmones y la consiguiente neumonitis química.
		EFFECTOS DE EXPOSICIÓN PROLONGADA O REPETIDA: El líquido desengrasa la piel.
PROPIEDADES FÍSICAS		
Punto de ebullición: 282-338 °C Punto de fusión: -30 - -18 °C Densidad: 0,87 - 0,95 g/cm³ Solubilidad en agua, g/100 ml a 20 °C: 0,0005		Punto de inflamación: 52 °C c.c. Temperatura de autoignición: 254-285 °C Límites de explosividad, % en volumen en el aire: 0,6 - 6,5 Coeficiente de reparto octanol/agua como log Pow: > 3,3
DATOS AMBIENTALES		
La sustancia es nociva para los organismos acuáticos.		
NOTAS		
En invierno los aditivos al Diesel pueden cambiar las propiedades físicas y toxicológicas de la sustancia. Esta ficha no está dirigida a la expulsión de vapores Diesel.		
INFORMACIÓN ADICIONAL		

Anexo C. Datos Modo de Operación Optimo (sin fallas).

FECHA	PROCESO			SISTEMA DE SELLADO 21/538										VIBRACIONES						VELOCIDAD	CORRIENTE	TEMPERATURAS									
	PRESION		FLUJO TOTAL	TEMPERATURA		NIVEL	PRESION	PRESION	TEMP SELLO	TEMP SELLO	TEMP FLUSHING	TEMP FLUSHING	MOTOR		BOMBA				MOTOR			MOTOR		MOTOR		BOMBA					
	SUCCION	DESCARGA		SUCCION	TORRE								LADO ACOPLE	LADO EMPUJE	LADO ACOPLE	LADO EMPUJE	LADO ACOPLE	LADO EMPUJE				LADO ACOPLE	LADO EMPUJE	LADO ACOPLE	LADO EMPUJE	RPM	AMP	LADO EMPUJE	LADO ACOPLE	LADO ACOPLE	LADO EMPUJE
15/04/2017	20	165	118033.35	999.39	50.05	129.21	129.80	120					0.05	0.02	0.36	0.22	0.36	0.55	1793	34	136.4	147.2	150.8	158							
16/04/2017	21	165	119330.03	998.20	49.99	130.37	130.34	125	120	302	200		0.03	0.02	0.36	0.25	0.36	0.49	1797	34	140	141	145	154							
17/04/2017	21	164	119996.52	998.84	49.93	131.92	131.03	125	120	310	200		0.03	0.02	0.34	0.22	0.374	0.5	1799	34	140	145.4	147.2	154.4							
17/04/2017	20.5	170	119538.95	998.85	50.01	128.40	126.16	128	127	302	190	0.0313	0.0275	0.3642	0.2136	0.3604	0.566	1797	34	145	145.4	147.2	154.4								
18/04/2017	21	165	119957.29	998.59	50.00	128.56	127.72	125	120	300	200	0.03	0.025	0.38	0.23	0.36	0.54	1793	33	145	145	149	154								
18/04/2017	20.5	157	118944.65	998.45	50.00	126.69	124.58	125	115	305	190	0.0328	0.0275	0.37	0.22	0.32	0.5	1799	34	145	143.6	145.4	154.4								
19/04/2017	21	165	118300.99	998.65	49.89	130.71	128.04	123	115	300	125	0.03	0.03	0.39	0.22	0.36	0.54	1797	35	145.4	145.4	149	154.4								
19/04/2017	20.5	165	118033.30	999.02	50.00	125.44	120.30	125	127	310	200	0.029	0.0244	0.3281	0.2002	0.3996	0.3471	1799	34	145.4	149	150	156								
20/04/2017	21	165	118284.01	998.17	50.01	125.48	119.86	125	120	305	200	0.0252	0.0237	0.36	0.22	0.34	0.49	1793	34	147.2	143.6	145.4	154.4								
21/04/2017	21	165	118460.44	997.80	51.18	123.04	117.47	127	120	305	200	0.0237	0.023	0.35	0.24	0.34	0.53	1799	34	136.4	150.8	152.6	158								
22/04/2017	21	165	119543.35	995.09	51.34	128.74	127.39	126	120	302	200	0.02	0.025	0.37	0.21	0.38	0.51	1799	34	140	152	152	158								
22/04/2017	20.8	165	118804.97	996.76	50.07	127.03	126.10	124	116	200	200	0.02	0.02	0.31	0.02	0.38	0.58	1797	33	136.4	152	152	158								
23/04/2017	20.5	165	114803.27	999.30	50.00	128.61	127.62	128	128	300	180	0.02	0.02	0.28	0.2	0.35	0.53	1800	34	147	141	145	152								
24/04/2017	20.5	165	1113230.00	600.00	49.99	132.58	131.23	120	115	300	200	0.02	0.02	0.31	0.21	0.35	0.55	1799	34	152	140	145	150								
25/04/2017	21	165	1115843.04	998.37	49.81	128.38	127.50	132	120	310	210	0.02	0.0113	0.3014	0.1307	0.351	0.5417	1798	35	143	152	152	158								
25/04/2017	21	165	118863.03	995.90	50.78	127.08	125.83	127	115	200	180	0.0305	0.03	0.31	0.22	0.36	0.55	1799	34	140	150.8	152.6	158								
26/04/2017	21	165	116504.67	995.11	50.02	126.13	124.32	130	125	310	200	0.02	0.0305	0.3061	0.2231	0.3528	0.545	1796	34	136.4	147.2	150.8	156								
27/04/2017	20.5	165	117062.12	993.66	50.04	125.79	124.47	123	123	303	200	0.02	0.03	0.33	0.24	0.38	0.57	1800	35	140	141	145	154								
28/04/2017	20.5	165	118197.53	992.74	50.06	128.73	127.89	305	120	310	200	0.02	0.034	0.31	0.24	0.39	0.51	1793	35	140	145.4	147.2	154.4								
1/05/2017	20.5	165	116115.30	993.72	51.93	124.90	123.04	120	119	200	200	0.02	0.025	0.37	0.21	0.38	0.51	1797	35	147.2	143.6	145.4	154.4								
3/05/2017	20.5	165	115462.80	993.99	51.97	125.73	124.11	135	130	305	220	0.02	0.02	0.28	0.2	0.35	0.53	1793	35	140	152	152	158								
3/05/2017	20.5	165	115431.94	994.40	52.02	123.51	121.01	125	112	200	200	0.0305	0.0388	0.32	0.21	0.39	0.55	1799	35	136.4	152	152	158								
5/05/2017	21	165	115030.98	994.04	53.06	128.00	125.59	130	120	310	200	0.025	0.02	0.35	0.21	0.36	0.51	1797	35	152	140	145	150								
5/05/2017	20.9	165	115711.48	994.11	53.07	124.51	122.27	122	110	300	250	0.02	0.03	0.39	0.22	0.36	0.54	1800	34	145.4	150	150	156								
6/05/2017	21	165	115632.35	994.13	53.09	126.13	124.36	125	120	310	200	0.029	0.0244	0.3281	0.2002	0.3996	0.3471	1800	33	143	152	152	158								
7/05/2017	20.5	165	116274.19	993.03	53.01	124.89	123.12	127	127	310	200	0.0252	0.0237	0.36	0.22	0.34	0.49	1799	31	143.6	141.8	147.2	154.4								
7/05/2017	20.5	165	111634.28	995.32	53.17	123.59	121.96	135	125	200	225	0.0237	0.023	0.35	0.24	0.34	0.53	1798	30	136.4	152	152	158								
10/05/2017	20.5	165	119508.55	995.53	53.27	123.06	121.12	125	130	310	230	0.0305	0.038	0.32	0.21	0.39	0.55	1800	33	143	152	152	158								
11/05/2017	21	165	119864.29	990.73	53.40	121.25	118.88	130	120	310	250	0.025	0.02	0.35	0.21	0.36	0.51	1797	34	136.4	147.2	150.8	156								
12/05/2017	21	165	119700.38	990.25	53.49	121.84	119.47	128	110	200	240	0.02	0.03	0.39	0.22	0.36	0.54	1799	34	138	145	149	154								
12/05/2017	20.5	165	119544.92	990.09	53.41	121.09	119.19	133	130	200	200	0.029	0.0244	0.3281	0.2002	0.3996	0.3471	1797	34	140	141	145	154								
14/05/2017	20.5	165	119748.46	989.92	53.52	121.75	119.71	130	125	305	230	0.02	0.025	0.37	0.21	0.38	0.51	1799	35	145	143.6	145.4	154.4								
16/05/2017	20.5	165	111541.93	989.90	53.71	127.11	126.42	130	130	300	200	0.025	0.02	0.35	0.21	0.36	0.51	1800	33	140	145.4	147.2	154.4								
19/05/2017	20.5	165	118611.71	984.45	53.83	128.35	127.47	112	112	300	211	0.029	0.0244	0.3281	0.2002	0.3996	0.3471	1799	34	145	145	149	154								
22/05/2017	20.5	165	118844.61	990.86	49.99	123.71	122.86	134	115	280	230	0.03	0.02	0.34	0.22	0.374	0.5	1800	34	141	147	149	156								
26/05/2017	20.5	165	120504.30	981.71	49.99	130.00	123.32	130	115	300	235	0.0252	0.0237	0.36	0.22	0.34	0.49	1799	35	143	152	152	158								
27/05/2017	20.5	165	120322.14	982.59	50.00	123.59	122.83	128	115	310	260	0.02	0.025	0.37	0.21	0.38	0.51	1797	36	136.4	147.2	150.8	156								
28/05/2017	21	165	120622.52	983.16	49.99	122.88	120.09	123	105	300	225	0.02	0.0305	0.3566	0.2269	0.3584	0.578	1799	35	140	141	145	154								
29/05/2017	21	165	120636.66	982.98	50.01	125.64	123.33	120	115	310	235	0.02	0.02	0.28	0.2	0.35	0.53	1797	35	140	145.4	147.2	154.4								
29/05/2017	20.5	165	120097.09	983.16	50.00	126.13	126.98	120	100	300	310	0.02	0.02	0.31	0.21	0.35	0.55	1799	35	145	145.4	147.2	154.4								
31/05/2017	20.5	165	119325.67	986.27	50.01	122.44	134.37	120	105	310	210	0.0305	0.03	0.31	0.22	0.36	0.55	1800	34	145.4	145.4	149	154.4								
31/05/2017	20.5	165	119518.30	985.76	49.83	117.17	128.68	120	115	305	200	0.031	0.028	0.31	0.21	0.39	0.57	1799	33	145.4	149	150	156								
1/06/2017	21	165	119937.34	984.91	50.03	119.75	123.92	115	100	305	200	0.02	0.0328	0.32	0.222	0.39	0.58	1798	31	147.2	143.6	145.4	154.4								
2/06/2017	21	165	119918.36	984.83	50.03	124.62	126.69	120	110	310	205	0.02	0.03	0.33	0.24	0.38	0.57	1799	30	136.4	150.8	152.6	158								
2/06/2017	20.5	165	119505.26	985.38	49.96	118.02	123.07	117	105	310	195	0.02	0.034	0.31	0.24	0.39	0.51	1797	33	141	147	149	156								
3/06/2017	21	165	119468.01	985.05	50.04	122.03	125.21	123	120	310	200	0.025	0.0305	0.3052	0.2116	0.3833	0.5895	1796	34	140	152	152	158								

Anexo D. Datos Modo de Operación Optimo (sin fallas).

FECHA	PROCESO			SISTEMA DE SELADO 21/538										VIBRACIONES						VELOCIDAD	CORRIENTE	TEMPERATURAS			
	PRESION		FLUJO TOTAL	TEMPERATURA		NIVEL	PRESION		TEMP SELLO	TEMP FLUSHING	TEMP FLUSHING	MOTOR		BOMBA		MOTOR	MOTOR	MOTOR				BOMBA			
	SUCCION	DESCARGA		SUCCION	TORRE		LADO ACOPLE	LADO EMPUJE				LADO ACOPLE	LADO EMPUJE	LADO ACOPLE	LADO EMPUJE			LADO ACOPLE	LADO EMPUJE			LADO EMPUJE	LADO ACOPLE	LADO EMPUJE	LADO EMPUJE
4/06/2017	20,5	165	119433,35	585,41	51,04	115,12	123,34	123	120	320	210	0,0305	0,038	0,32	0,21	0,39	0,55	1800	36	140	154,4	154,4	158,8		
4/06/2017	20,5	165	118795,02	587,34	51,02	124,90	120,47	125	110	319	210	0,0205	0,0313	0,35	0,21	0,39	0,55	1793	33	147	141	145	152		
8/06/2017	20,5	165	114304,53	589,90	51,62	119,20	123,69	127	125	319	210	0,0305	0,038	0,32	0,21	0,39	0,55	1797	33	140	154,4	154,4	158,8		
9/06/2017	20,5	165	118942,18	587,39	50,87	122,28	123,43	123	120	210	195	0,0205	0,02	0,35	0,21	0,36	0,51	1793	34	140,4	150	150	156		
16/06/2017	21	165	113740,44	589,53	50,03	124,11	124,12	130	115	315	205	0,02	0,03	0,39	0,22	0,36	0,54	1800	34	136,4	147,2	150,8	156		
25/06/2017	21	165	110320,57	596,03	49,97	116,93	118,75	125	125	320	220	0,0252	0,0237	0,36	0,22	0,34	0,49	1799	34	145,4	150	150	156		
26/06/2017	21	165	112468,77	597,60	50,04	119,94	120,69	125	112	325	220	0,0237	0,023	0,35	0,24	0,34	0,53	1799	33	143	152	152	158		
11/07/2017	20,5	165	110899,68	589,76	50,01	120,40	123,67	120	115	320	210	0,03	0,02	0,34	0,22	0,374	0,5	1799	34	143	152	152	158		
16/10/2017	20	170	112746,65	595,82	51,04	126,29	124,91	125	105	325	205	0,02	0,0305	0,3566	0,2269	0,3584	0,578	1799	34	145	143,6	145,4	154,4		
17/10/2017	20	170	115278,06	593,07	51,01	124,48	125,35	120	110	325	190	0,02	0,02	0,31	0,21	0,35	0,55	1799	34	140,4	149	150	156		
18/10/2017	20	170	117673,55	589,63	51,06	126,89	126,86	125	115	325	190	0,02	0,0313	0,3014	0,1937	0,351	0,5417	1796	33	136,4	147,2	150,8	156		
21/10/2017	22	170	117944,33	588,33	50,99	121,93	120,60	130	120	317	190	0,02	0,03	0,33	0,24	0,38	0,57	1797	34	145	145	149	154		
23/10/2017	20,5	167	117760,97	588,02	51,00	122,22	120,33	135	115	250	190	0,0252	0,0237	0,36	0,22	0,34	0,49	1797	35	147,2	143,6	145,4	154,4		
24/10/2017	20,5	166	118607,90	587,63	50,99	122,30	120,75	125	120	260	190	0,0237	0,023	0,35	0,24	0,34	0,53	1799	35	136,4	150,8	152,6	158		
24/10/2017	21	168	118899,44	587,83	50,98	119,24	118,06	125	110	240	190	0,05	0,02	0,36	0,22	0,36	0,55	1797	34	141	147	149	156		
25/10/2017	22,5	168	119005,57	587,68	51,06	118,87	119,26	132	110	200	190	0,0267	0,03	0,35	0,22	0,36	0,51	1793	35	140	152	152	158		
27/10/2017	20,5	170	117438,52	584,16	49,99	132,17	128,17	127	120	202	190	0,03	0,025	0,38	0,23	0,36	0,54	1797	35	152	140	145	150		
27/10/2017	20	166	118154,47	584,76	50,03	126,94	123,14	130	115	200	200	0,0328	0,0275	0,37	0,22	0,32	0,5	1800	36	145,4	150	150	156		
28/10/2017	20	168	113739,15	584,79	49,99	130,69	127,07	128	120	200	200	0,03	0,03	0,39	0,22	0,36	0,54	1800	36	143	152	152	158		
28/10/2017	20	168	113796,40	591,33	49,95	124,07	123,61	133	115	202	200	0,029	0,0244	0,3281	0,2002	0,3396	0,3471	1799	35	140	150,8	152,6	158		
29/10/2017	20	168	117248,85	588,09	49,97	122,57	121,57	133	100	290	200	0,0252	0,0237	0,36	0,22	0,34	0,49	1798	35	136,4	147,2	150,8	156		
30/10/2017	22	168	116643,47	584,36	50,02	125,61	127,57	130	111	295	210	0,0237	0,023	0,35	0,24	0,34	0,53	1799	35	138	145	149	154		
30/10/2017	20	166	115694,78	590,63	50,09	123,62	124,77	130	115	298	200	0,02	0,0305	0,3566	0,2269	0,3584	0,578	1797	35	140	141	145	154		
31/10/2017	20	165	114402,74	593,46	50,02	128,20	126,35	130	120	300	210	0,02	0,02	0,28	0,2	0,35	0,53	1796	34	140	145,4	147,2	154,4		
31/10/2017	19,5	164	113342,62	593,30	50,10	123,64	120,65	125	100	300	200	0,02	0,02	0,31	0,21	0,35	0,55	1799	33	145	145,4	147,2	154,4		
1/11/2017	20	168	113914,43	593,89	50,00	124,96	123,26	123	105	300	200	0,025	0,034	0,31	0,22	0,38	0,57	1800	32	145	145	149	154		
1/11/2017	20,2	166	111282,22	591,88	50,03	121,08	120,47	120	100	300	200	0,02	0,0313	0,3014	0,1937	0,351	0,5417	1793	31	145	143,6	145,4	154,4		
2/11/2017	21	168	111246,04	590,83	50,00	123,87	131,03	120	123	302	200	0,0305	0,03	0,31	0,22	0,36	0,55	1799	30	140,4	145,4	149	154,4		
6/11/2017	20,5	163	110595,67	590,28	50,04	123,73	120,17	130	120	305	200	0,0252	0,0237	0,36	0,22	0,34	0,49	1793	34	147	141	145	152		
7/11/2017	20	163	111948,34	591,83	50,01	123,23	120,55	120	118	305	200	0,0237	0,023	0,35	0,24	0,34	0,53	1799	34	152	140	145	150		
7/11/2017	19	168	113560,34	591,23	49,99	121,48	117,56	124	105	300	200	0,05	0,02	0,36	0,22	0,36	0,55	1797	34	145,4	150	150	156		
8/11/2017	20	164	115195,09	590,28	50,01	122,80	118,75	130	120	308	200	0,0267	0,03	0,35	0,22	0,36	0,51	1799	33	143	152	152	158		
9/11/2017	20	165	112626,83	585,71	49,95	121,99	128,89	135	115	304	190	0,02	0,0305	0,3566	0,2269	0,3584	0,578	1800	35	143,6	141,8	147,2	154,4		
9/11/2017	21	168	112298,10	590,94	50,01	120,57	124,55	125	121	308	190	0,02	0,02	0,28	0,2	0,35	0,53	1800	34	136,4	152	152	158		
10/11/2017	22	165	113892,70	594,90	49,99	131,49	131,45	125	121	308	200	0,02	0,02	0,31	0,21	0,35	0,55	1799	34	140	154,4	154,4	158,8		
10/11/2017	21	168	114154,28	595,71	50,03	127,96	125,82	130	105	305	200	0,025	0,034	0,31	0,22	0,38	0,57	1799	34	147	141	145	152		
11/11/2017	21	165	113082,70	596,81	49,86	129,62	128,04	130	110	305	190	0,02	0,0313	0,3014	0,1937	0,351	0,5417	1798	34	152	140	145	150		
11/11/2017	21,5	165	112343,35	597,19	50,00	127,27	122,94	126	110	305	190	0,0305	0,03	0,31	0,22	0,36	0,55	1799	33	140,4	150	150	156		
12/11/2017	21	165	111890,24	597,40	50,15	129,39	123,70	123	120	310	195	0,031	0,028	0,31	0,21	0,39	0,57	1797	34	143	152	152	158		
12/11/2017	21	164	111578,13	596,59	50,00	125,74	117,87	128	115	305	195	0,02	0,0305	0,3261	0,2231	0,3528	0,545	1796	33	140	150,8	152,6	158		
13/11/2017	20,5	165	111285,02	593,99	51,58	127,94	120,08	125	120	310	190	0,02	0,0328	0,32	0,222	0,39	0,58	1799	33	143,6	141,8	147,2	154,4		
13/11/2017	21	165	111583,94	595,52	51,93	124,67	119,70	123	110	310	200	0,02	0,03	0,33	0,24	0,38	0,57	1800	34	136,4	147,2	150,8	156		
14/11/2017	20,5	162	112474,95	595,36	51,99	122,82	125,42	120	120	310	200	0,025	0,02	0,35	0,21	0,36	0,51	1793	34	138	145	149	154		
14/11/2017	20	165	114095,75	593,65	51,94	119,90	121,34	120	119	310	200	0,02	0,03	0,39	0,22	0,36	0,54	1799	33	140	141	145	154		
15/11/2017	20	164	112811,46	592,23	52,09	119,33	118,01	125	117	312	200	0,029	0,0244	0,3281	0,2002	0,3396	0,3471	1797	35	140	145,4	147,2	154,4		
16/11/2017	21	170	113327,74	593,53	51,85	129,41	126,02	120	105	312	206	0,0252	0,0237	0,36	0,22	0,34	0,49	1797	34	145	145	149	154		
16/11/2017	21,5	164	112997,71	590,81	53,95	126,39	118,65	120	100	310	206	0,0237	0,023	0,35	0,24	0,34	0,53	1793	34	145	143,6	145,4	154,4		

Anexo E. Datos Modo de Operación Optimo (sin fallas).

FECHA	PROCESO					SISTEMA DE SELLADO 21/538								VIBRACIONES				VELOCIDAD	CORRIENTE	TEMPERATURAS				
	PRESION		FLUIDO TOTAL	TEMPERATURA		NIVEL	PRESION	PRESION	TEMP SELLO	TEMP SELLO	TEMP FLUSHING	TEMP FLUSHING	MOTOR		BOMBA		MOTOR			MOTOR		BOMBA		
	SUCCION	DESCARGA		SUCCION	TORRE								LADO ACOPLE	LADO EMPUJE	LADO ACOPLE	LADO EMPUJE						LADO ACOPLE	LADO EMPUJE	LADO ACOPLE
17/11/2017	22	164	118414,15	583,74	67,65	129,34	120,99	125	110	310	305	0,05	0,02	0,36	0,22	0,36	0,55	1799	34	145,4	145,4	149	154,4	
17/11/2017	21	164	118986,36	582,43	52,91	125,66	128,61	115	115	315	205	0,0267	0,03	0,35	0,22	0,36	0,51	1797	35	145,4	149	150	156	
18/11/2017	20,5	166	120714,28	583,08	53,42	127,36	127,03	120	105	315	200	0,0305	0,038	0,32	0,21	0,39	0,55	1799	35	147,2	154	159	160	
18/11/2017	20	165	121347,57	590,09	51,78	124,36	122,99	117	105	310	200	0,005	0,0313	0,35	0,21	0,39	0,55	1797	35	138,4	147,2	150,8	156	
19/11/2017	21	165	120888,15	591,65	51,37	127,44	126,13	123	100	315	205	0,005	0,0321	0,3566	0,2213	0,38	0,53	1793	34	138	145	149	154	
19/11/2017	20	165	120540,35	594,42	51,22	125,97	120,59	120	100	312	200	0,0305	0,02	0,35	0,21	0,36	0,51	1789	35	140	141	145	154	
20/11/2017	20,5	165	120310,19	595,00	51,26	128,40	118,71	123	115	315	195	0,02	0,005	0,37	0,21	0,38	0,51	1797	35	140	145,4	147,2	154,4	
20/11/2017	20	165	119837,38	595,78	50,20	128,10	122,33	125	110	310	195	0,02	0,02	0,31	0,02	0,38	0,58	1799	35	145	145,4	147,2	154,4	
21/11/2017	20,5	165	119521,89	595,30	50,22	130,39	125,30	123	105	312	200	0,02	0,0305	0,3566	0,2289	0,3584	0,578	1797	35	145	145	149	154	
21/11/2017	20	165	117664,13	596,02	50,09	129,01	121,09	125	105	310	210	0,02	0,02	0,28	0,2	0,35	0,53	1800	35	145	143,6	145,4	154,4	
22/11/2017	19,5	164	115464,02	596,77	50,57	133,68	122,52	125	120	320	220	0,0305	0,058	0,32	0,21	0,39	0,55	1800	36	145,4	145,4	149	154,4	
23/11/2017	20	164	121722,21	594,53	50,22	127,43	123,78	125	115	318	210	0,005	0,02	0,35	0,21	0,36	0,51	1788	35	147,2	143,6	145,4	154,4	
24/11/2017	20,5	166	122376,37	594,61	50,15	128,32	123,31	127	125	320	210	0,02	0,03	0,39	0,22	0,36	0,54	1793	35	136,4	150,8	152,6	158	
24/11/2017	19,6	164	123426,82	599,52	50,09	129,09	124,91	125	105	315	210	0,009	0,0344	0,3281	0,2002	0,3396	0,3471	1799	35	141	147	149	156	
25/11/2017	20	165	121139,00	601,27	50,15	131,50	121,41	123	100	310	210	0,0052	0,0237	0,36	0,22	0,34	0,49	1799	34	136,4	152	152	158	
26/11/2017	20	165	120763,30	601,21	50,12	131,75	124,72	127	115	310	210	0,0237	0,023	0,35	0,24	0,34	0,53	1797	33	140	154,4	154,4	159,8	
26/11/2017	20,5	165	120518,59	601,99	50,15	129,93	117,96	116	110	310	200	0,02	0,005	0,37	0,21	0,38	0,51	1793	32	147	141	145	152	
27/11/2017	20	165	119384,86	600,81	50,15	131,32	118,85	120	115	310	200	0,02	0,02	0,31	0,02	0,38	0,58	1799	31	152	140	145	150	
2/12/2017	20	163	120133,12	483,24	50,46	120,38	113,59	130	100	320	200	0,0237	0,023	0,35	0,24	0,34	0,53	1799	34	145	143,6	145,4	154,4	
3/12/2017	20	165	118171,76	544,05	50,96	128,97	125,62	130	116	322	200	0,02	0,005	0,37	0,21	0,38	0,51	1799	34	145,4	145,4	149	154,4	
3/12/2017	20	165	118394,05	590,15	50,63	128,39	122,87	124	100	318	200	0,02	0,02	0,31	0,02	0,38	0,58	1788	33	145,4	149	150	156	
4/12/2017	20	165	120530,18	588,16	50,57	132,06	125,50	130	120	322	200	0,02	0,0305	0,3566	0,2289	0,3584	0,578	1799	34	147,2	154	159	160	
4/12/2017	20	165	121980,68	588,06	50,66	128,15	119,09	128	110	315	200	0,02	0,02	0,28	0,2	0,35	0,53	1797	35	147,2	143,6	145,4	154,4	
6/12/2017	20	166	122762,68	592,60	51,21	130,17	119,70	124	110	315	200	0,005	0,02	0,35	0,21	0,36	0,51	1793	34	136,4	152	152	158	
7/12/2017	20,5	164	121770,79	592,30	51,03	128,45	127,63	120	110	320	200	0,009	0,0344	0,3281	0,2002	0,3396	0,3471	1797	34	147	141	145	152	
9/12/2017	21	162	120184,37	591,43	51,00	125,93	121,29	125	115	310	220	0,0237	0,023	0,35	0,24	0,34	0,53	1793	34	143	152	152	158	
10/12/2017	20	164	130278,11	590,91	52,45	125,60	125,93	125	125	325	200	0,0267	0,03	0,35	0,22	0,36	0,51	1797	34	143,6	141,8	147,2	154,4	
10/12/2017	21	165	120499,87	592,45	51,61	125,57	126,13	123	125	322	230	0,03	0,02	0,36	0,25	0,36	0,49	1799	34	136,4	152	152	158	
11/12/2017	20	165	120095,56	591,72	51,64	134,30	131,05	125	105	320	250	0,0313	0,0075	0,3642	0,2136	0,3604	0,566	1793	34	147	141	145	152	
12/12/2017	20	165	130423,44	591,30	51,68	123,00	127,63	124	112	315	250	0,0308	0,0375	0,37	0,22	0,32	0,5	1787	34	145,4	150	150	156	
16/12/2017	20	164	130588,66	591,58	61,43	134,75	127,16	120	112	315	250	0,02	0,02	0,31	0,02	0,38	0,58	1799	34	145	145,4	147,2	154,4	
23/12/2017	21	164	120547,76	590,01	51,70	125,79	119,51	135	100	315	215	0,0305	0,058	0,32	0,21	0,39	0,55	1797	35	145,4	149	150	156	
24/12/2017	20,5	163	120419,96	590,19	51,71	123,78	121,81	128	105	310	225	0,005	0,0321	0,3566	0,2213	0,38	0,53	1799	35	147,2	143,6	145,4	154,4	
25/12/2017	20	163	120951,72	590,35	51,65	124,77	131,64	123	115	300	211	0,0305	0,02	0,35	0,21	0,36	0,51	1797	36	136,4	150,8	152,6	158	
26/12/2017	21	164	121058,05	590,21	51,68	121,19	121,81	123	107	305	230	0,02	0,005	0,37	0,21	0,38	0,51	1799	36	141	147	149	156	
26/12/2017	20,5	163	130732,89	590,69	51,64	121,65	122,49	130	110	305	200	0,02	0,02	0,31	0,02	0,38	0,58	1787	35	140	152	152	158	
26/12/2017	22	162	130759,37	588,93	51,67	126,26	125,13	123	105	305	230	0,02	0,0305	0,3566	0,2289	0,3584	0,578	1800	35	136,4	152	152	158	
27/12/2017	20,5	163	121137,11	589,01	51,67	127,31	126,09	120	108	305	230	0,02	0,02	0,28	0,2	0,35	0,53	1800	35	140	154,4	154,4	159,8	
27/12/2017	21	162	121133,32	586,65	51,68	123,69	127,01	123	110	310	230	0,0305	0,058	0,32	0,21	0,39	0,55	1799	35	147	141	145	152	
29/12/2017	21	165	122253,06	584,59	51,66	131,12	130,96	125	95	292	200	0,005	0,02	0,35	0,21	0,36	0,51	1799	33	143	152	152	158	
29/12/2017	20	170	122462,52	584,53	51,69	130,14	126,45	125	115	300	230	0,02	0,03	0,39	0,22	0,36	0,54	1797	32	140	150,8	152,6	158	
31/12/2017	20,7	170	121749,16	584,75	51,66	134,10	122,57	125	105	300	210	0,0052	0,0237	0,36	0,22	0,34	0,49	1800	33	138	145	149	154	
31/12/2017	20,5	164	121562,49	586,08	51,67	131,45	120,11	125	110	310	240	0,0237	0,023	0,35	0,24	0,34	0,53	1793	34	140	141	145	154	
2/01/2018	20,5	164	121486,56	591,05	49,99	124,98	123,28	135	100	310	260	0,02	0,02	0,28	0,2	0,35	0,53	1797	34	145	143,6	145,4	154,4	
4/01/2018	21	165	122521,85	585,15	50,02	138,36	125,64	127	115	310	310	0,005	0,02	0,35	0,21	0,36	0,51	1799	34	147,2	143,6	145,4	154,4	
5/01/2018	20	164	122360,59	585,12	50,02	130,29	125,90	124	110	310	210	0,02	0,03	0,39	0,22	0,36	0,54	1797	34	136,4	150,8	152,6	158	
5/01/2018	20	164	122186,78	588,93	50,02	128,24	120,30	130	105	318	210	0,009	0,0344	0,3281	0,2002	0,3396	0,3471	1793	33	141	147	149	156	

Anexo F. Datos Modo de Falla Sello Mecánico.

FECHA	PROCESO					SISTEMA DE SELADO 21/38										VIBRACIONES						VELOCIDAD	CORRIENTE	TEMPERATURAS			
	PRESION		FLUJO TOTAL	TEMPERATURA		PRESION	PRESION	TEMP SELLO	TEMP SELLO	TEMP FLUSHING	TEMP FLUSHING	MOTOR		BOMBA				MOTOR	MOTOR					BOMBA			
	SUCCION	DESCARGA		SUCCION	TORRE	LADO ACOPL	LADO EMPUJE	LADO ACOPL	LADO EMPUJE	LADO ACOPL	LADO EMPUJE	LADO ACOPL	LADO EMPUJE	LADO ACOPL	LADO EMPUJE	LADO EMPUJE	LADO ACOPL		LADO ACOPL	LADO EMPUJE							
	psi	psi		BPD	° F	%	psig	psig	° F	° F	° F	° F	IN/SEC	IN/SEC	MIL	MIL	MIL		MIL	RPM	AMP			° F	° F	° F	° F
15/04/2017	20	165	116853,35	599,39	50,03	129,21	129,80	120	108	300	200	0,05	0,02	0,36	0,22	0,36	0,55	1793	34	136,4	147,2	150,8	156				
14/07/2017	21	145	109993,96	585,18	49,99	102,63	132,09	124	124	318	200	0,029	0,244	0,396	0,2403	0,3757	0,3777	1797	35	140	145,4	147,2	154,4				
18/07/2017	20,5	165	110984,21	594,42	49,91	0,25	-1,19	120	115	330	200	0,02	0,02	0,31	0,21	0,35	0,55	1797	36	138	145	149	154				
15/10/2017	21	170	112099,39	601,14	51,00	18,87	12,86	130	125	330	220	0,02	0,025	0,37	0,21	0,38	0,51	1800	34	145	145,4	147,2	154,4				
3/04/2018	20	165	118541,26	592,75	50,09	105,89	113,21	125	120	320	210	0,02	0,0313	0,3014	0,3357	0,351	0,5417	1799	35	140	141	145	154				
21/05/2018	20	165	64,11	267,90	50,00	26,90	4,70	130	125	320	200	0,0252	0,0237	0,36	0,22	0,34	0,49	1799	34	145	145	149	154				
23/05/2018	20	165	63,54	134,31	49,99	22,96	3,23	130	125	325	195	0,02	0,0305	0,3566	0,2269	0,3584	0,578	1793	35	147,2	154	159	160				
28/05/2018	20	165	118860,05	586,95	50,02	24,09	0,22	123	123	320	130	0,05	0,02	0,36	0,22	0,36	0,55	1797	35	147,2	143,6	145,4	154,4				
29/05/2018	21	165	122675,29	579,05	49,97	17,18	0,92	125	125	325	200	0,03	0,02	0,36	0,25	0,36	0,49	1799	35	141	147	149	156				
1/06/2018	21	164	123709,72	579,66	49,99	14,11	1,91	125	128	325	200	0,03	0,03	0,39	0,22	0,36	0,54	1799	31	152	140	145	150				
5/06/2018	21	164	122948,36	595,30	1,77	11,32	7,43	125	125	320	180	0,02	0,0305	0,3566	0,2269	0,3584	0,578	1799	34	140	145,4	147,2	154,4				
6/06/2018	20	162	120891,79	566,91	8,22	9,96	5,56	132	115	323	210	0,025	0,034	0,31	0,22	0,38	0,57	1797	34	145	143,6	145,4	154,4				
18/07/2018	21	164	122288,57	576,04	53,29	36,91	36,53	128	124	330	205	0,02	0,0305	0,3261	0,2231	0,3528	0,545	1796	35	143	152	152	158				
18/07/2018	20	164	122366,72	580,33	49,90	34,76	26,87	127	124	321	210	0,02	0,0328	0,32	0,222	0,39	0,58	1799	35	140	150,8	152,6	158				
19/07/2018	21	164	123025,94	575,69	51,34	53,42	51,91	120	120	320	210	0,02	0,03	0,33	0,24	0,38	0,57	1800	35	143,6	141,8	147,2	154,4				
17/07/2017	21	150	108579,47	591,67	50,00	101,81	108,53	130	132	340	195	0,02	0,0305	0,3566	0,2269	0,3584	0,578	1793	35	147,2	154	159	160				
20/06/2017	21	166	116706,90	580,73	50,01	1,18	-0,80	125	120	340	210	0,02	0,03	0,39	0,22	0,36	0,54	1800	34	145	145	149	154				
28/02/2018	20	165	107318,72	593,81	50,04	128,40	132,09	120	130	316	225	0,35	0,0313	0,35	0,21	0,39	0,55	1799	34	145,4	150	150	156				
20/03/2018	20,5	163	118498,78	584,40	49,97	129,57	62,42	125	115	330	235	0,0305	0,038	0,32	0,21	0,39	0,55	1799	34	145	143,6	145,4	154,4				
6/04/2018	20	165	123046,50	591,69	50,04	126,07	70,18	135	126	318	220	0,02	0,03	0,33	0,24	0,38	0,57	1800	36	145,4	145,4	149	154,4				
8/04/2018	20	165	120310,33	583,38	49,93	125,67	66,87	130	115	330	205	0,0305	0,038	0,32	0,21	0,39	0,55	1799	35	136,4	150,8	152,6	158				
16/04/2018	21	164	121011,30	586,67	50,05	129,29	57,01	120	125	330	205	0,0237	0,023	0,35	0,24	0,34	0,53	1799	34	143	152	152	158				
1/05/2018	21	164	122571,76	577,45	49,99	128,28	49,22	125	120	300	200	0,03	0,02	0,34	0,22	0,374	0,5	1800	35	152	140	145	150				
18/05/2018	21,5	164	120314,01	590,30	53,49	122,30	43,11	114	115	322	205	0,39	0,0321	0,3566	0,2213	0,38	0,53	1799	34	136,4	147,2	150,8	156				
18/07/2018	20	164	122366,72	580,33	49,90	34,76	26,87	127	124	321	210	0,02	0,0328	0,32	0,222	0,39	0,58	1799	35	140	150,8	152,6	158				
CODIGOS DE FALLA	D7		D6	D8	D9	D1	D2		D3	D4		D5															

Anexo G. Datos Modo de Falla de Rodamientos.

FECHA	PROCESO						SISTEMA DE SELLADO 21/33B								VIBRACIONES						VELOCIDAD	CORRIENTE	TEMPERATURAS								
	PRESION		FLUJO TOTAL	TEMPERATURA		NIVEL	PRESION	PRESION	TEMP SELLO	TEMP SELLO	TEMP FLUSHING	TEMP FLUSHING	MOTOR		BOMBA				MOTOR	MOTOR			BOMBA								
	SUCCION	DESCARGA		SUCCION	TORRE								LADO ACOPLIE	LADO EMPUJE	LADO ACOPLIE	LADO EMPUJE	LADO ACOPLIE	LADO EMPUJE		MIL			MIL	MIL	MIL	RPM	AMP	LADO EMPUJE	LADO ACOPLIE	LADO ACOPLIE	LADO EMPUJE
4/05/2017	20,5	150	116086,00	594,34	52,03		124,62	122,87	125	120	305	200	0,35	0,0313	0,35	0,21	0,39	0,55	1797	35	140	154,4	154,4	154,4	159,8						
4/05/2017	21	165	116263,02	595,13	52,36		123,79	122,08	128	112	310	230	0,39	0,0321	0,3566	0,2213	0,38	0,53	1799	35	147	141	145	152	152						
10/05/2017	20,5	165	118894,81	592,23	53,43		121,06	118,89	130	115	300	250	0,35	0,0313	0,35	0,21	0,39	0,55	1795	34	140	150,8	152,6	158	158						
11/05/2017	20,5	150	118899,10	591,52	53,37		123,02	121,06	127	127	310	230	0,39	0,0321	0,3566	0,2213	0,38	0,53	1799	34	143,6	141,8	147,2	154,4	154,4						
17/05/2017	21	140	118416,82	587,02	54,01		127,45	126,99	120	116	200	235	0,35	0,0313	0,35	0,21	0,39	0,55	1799	33	138	145	149	154	154						
17/05/2017	20,5	150	117584,37	586,87	54,06		124,14	123,22	125	120	295	215	0,39	0,0321	0,3566	0,2213	0,38	0,53	1797	34	140	141	145	154	154						
8/06/2017	21	150	114534,31	590,06	51,76		127,07	126,02	125	120	310	205	0,35	0,0313	0,35	0,21	0,39	0,55	1799	34	147	141	145	152	152						
9/06/2017	20,5	165	115685,63	586,99	51,79		123,29	123,67	128	125	320	215	0,39	0,0321	0,3566	0,2213	0,38	0,53	1797	35	152	140	145	150	150						
15/06/2017	20,5	165	114487,73	587,46	50,09		121,06	124,46	125	130	329	200	0,35	0,0313	0,35	0,21	0,39	0,55	1797	35	145,4	145,4	149	154,4	154,4						
15/06/2017	20,5	165	114857,40	588,58	49,99		124,45	120,33	125	125	329	205	0,39	0,0321	0,3566	0,2213	0,38	0,53	1796	34	145,4	149	150	156	156						
21/06/2017	21	150	109586,12	596,31	50,30		126,54	121,59	120	120	330	205	0,35	0,0313	0,35	0,21	0,39	0,55	1797	35	147,2	143,6	145,4	154,4	154,4						
22/06/2017	21	140	110639,93	599,73	50,21		126,62	126,16	125	120	332	205	0,39	0,0321	0,3566	0,2213	0,38	0,53	1793	36	136,4	150,8	152,6	158	158						
29/06/2017	20,5	150	111336,40	598,50	50,00		118,08	121,85	125	115	335	190	0,35	0,0313	0,35	0,21	0,39	0,55	1800	35	140	145,4	147,2	154,4	154,4						
29/06/2017	21	165	112850,47	599,13	49,99		121,31	123,88	120	120	340	190	0,39	0,0321	0,3566	0,2213	0,38	0,53	1793	36	145	145,4	147,2	154,4	154,4						
5/07/2017	20,5	150	110875,18	593,76	50,02		121,58	120,02	125	124	340	200	0,35	0,0313	0,35	0,21	0,39	0,55	1797	34	147	141	145	152	152						
6/07/2017	20,5	165	110735,28	592,60	50,03		121,19	121,23	132	132	340	190	0,39	0,0321	0,3566	0,2213	0,38	0,53	1799	34	152	140	145	150	150						
28/07/2017	21	0	117132,90	587,58	51,02		1,11	-1,07	130	120	350	205	0,35	0,0313	0,35	0,21	0,39	0,55	1797	34	143,6	141,8	147,2	154,4	154,4						
28/07/2017	21	160	116681,97	588,93	50,89		1,08	-1,29	130	130	350	205	0,39	0,0321	0,3566	0,2213	0,38	0,53	1799	34	136,4	147,2	150,8	156	156						
3/08/2017	20,5	165	116426,42	586,20	50,86		1,11	-1,23	114	115	350	210	0,35	0,0313	0,35	0,21	0,39	0,55	1799	34	141	147	149	156	156						
4/08/2017	21	150	116318,17	588,98	50,73		1,15	-0,91	117	107	345	210	0,39	0,0321	0,3566	0,2213	0,38	0,53	1797	34	140	152	152	158	158						
10/08/2017	21	165	114934,78	584,49	50,74		1,12	-1,30	127	130	350	180	0,35	0,0313	0,35	0,21	0,39	0,55	1799	35	152	140	145	150	150						
10/08/2017	20	165	115648,23	582,69	50,78		1,10	-1,42	125	130	350	200	0,39	0,0321	0,3566	0,2213	0,38	0,53	1797	35	145,4	150	150	156	156						
1/09/2017	20	165	114759,90	579,22	50,80		1,14	-1,22	125	115	332	200	0,35	0,0313	0,35	0,21	0,39	0,55	1799	34	145,4	149	150	156	156						
2/09/2017	20	165	116264,34	580,24	50,66		1,17	-0,84	122	115	330	230	0,39	0,0321	0,3566	0,2213	0,38	0,53	1797	35	147,2	154	159	160	160						
8/09/2017	21	0	115074,07	576,17	52,05		1,17	-1,17	125	110	335	211	0,35	0,0313	0,35	0,21	0,39	0,55	1800	35	143,6	141,8	147,2	154,4	154,4						
8/09/2017	20,5	0	115802,26	576,76	51,95		1,12	-1,51	125	120	340	230	0,39	0,0321	0,3566	0,2213	0,38	0,53	1799	35	136,4	152	152	158	158						
14/09/2017	21	155	117796,56	577,46	51,01		1,15	-1,22	115	110	340	240	0,35	0,0313	0,35	0,21	0,39	0,55	1797	33	145	145,4	147,2	154,4	154,4						
15/09/2017	20	168	118048,97	576,98	51,05		1,17	-1,01	120	120	340	235	0,39	0,0321	0,3566	0,2213	0,38	0,53	1793	34	145	145	149	154	154						
18/09/2017	19,5	168	111310,58	579,43	50,05		1,16	-1,25	120	115	340	310	0,35	0,0313	0,35	0,21	0,39	0,55	1797	34	140	141	145	154	154						
19/09/2017	20	165	111308,69	579,45	50,06		1,16	-0,95	118	112	340	210	0,39	0,0321	0,3566	0,2213	0,38	0,53	1799	35	140	145,4	147,2	154,4	154,4						
5/10/2017	21	170	109412,30	598,15	49,86		1,16	-1,35	123	130	300	200	0,35	0,0313	0,35	0,21	0,39	0,55	1799	35	140	152	152	158	158						
5/10/2017	21	170	111395,44	596,15	50,03		1,15	-1,37	125	125	300	205	0,39	0,0321	0,3566	0,2213	0,38	0,53	1797	34	136,4	152	152	158	158						
22/11/2017	20	165	116121,64	595,44	50,16		129,74	124,54	108	105	315	210	0,35	0,0313	0,35	0,21	0,39	0,55	1799	36	145,4	149	150	156	156						
23/11/2017	19,5	166	119637,25	594,44	50,01		130,48	131,33	118	115	311	220	0,39	0,0321	0,3566	0,2213	0,38	0,53	1799	35	147,2	154	159	160	160						
29/11/2017	20	165	121415,09	592,46	50,20		125,26	129,84	115	110	325	200	0,35	0,0313	0,35	0,21	0,39	0,55	1793	35	143,6	141,8	147,2	154,4	154,4						
29/11/2017	20	165	122287,34	592,68	49,92		126,41	121,16	117	115	320	180	0,39	0,0321	0,3566	0,2213	0,38	0,53	1799	36	136,4	147,2	150,8	156	156						
5/12/2017	20	165	123008,35	579,10	52,77		130,89	124,35	130	120	328	180	0,35	0,0313	0,35	0,21	0,39	0,55	1799	34	141	147	149	156	156						
6/12/2017	22	165	123038,28	597,63	52,88		133,69	126,71	125	110	325	200	0,39	0,0321	0,3566	0,2213	0,38	0,53	1800	34	140	152	152	158	158						
28/12/2017	21	165	120746,76	585,84	51,72		126,75	134,20	125	110	310	228	0,35	0,0313	0,35	0,21	0,39	0,55	1799	35	152	140	145	150	150						
28/12/2017	21,5	164	121118,99	584,67	51,86		124,98	126,26	125	125	290	230	0,39	0,0321	0,3566	0,2213	0,38	0,53	1798	34	145,4	150	150	156	156						
3/01/2018	20	165	121546,84	592,31	50,01		132,66	124,12	128	105	310	225	0,35	0,0313	0,35	0,21	0,39	0,55	1799	34	145,4	149	150	156	156						
4/01/2018	20	170	122252,25	587,89	49,99		135,59	122,54	125	115	318	235	0,39	0,0321	0,3566	0,2213	0,38	0,53	1797	34	147,2	154	159	160	160						
10/01/2018	20	164	121274,04	591,91	50,00		133,35	124,42	125	115	320	230	0,35	0,0313	0,35	0,21	0,39	0,55	1798	33	143,6	141,8	147,2	154,4	154,4						
10/01/2018	20	164	119867,43	591,89	50,05		130,04	118,49	120	115	340	210	0,39	0,0321	0,3566	0,2213	0,38	0,53	1799	33	136,4	152	152	158	158						
17/01/2018	21	164	119096,45	593,51	50,14		123,18	119,12	125	125	330	200	0,35																		

Anexo H. Datos Modo de Falla de Enfriadores.

FECHA	PROCESO					SISTEMA DE SELLADO 21/538										VIBRACIONES						VELOCIDAD	CORRIENTE	TEMPERATURAS									
	PRESION		FLUJO TOTAL	TEMPERATURA		NIVEL	PRESION	PRESION	TEMP SELLO	TEMP FLUSHING	TEMP FLUSHING	MOTOR		BOMBA				MOTOR	MOTOR	MOTOR				BOMBA									
	SUCCION	DESCARGA		SUCCION	TORRE							LADO ACOPILE	LADO EMPUJE	LADO ACOPILE	LADO EMPUJE	LADO ACOPILE	LADO EMPUJE			LADO ACOPILE	LADO EMPUJE			LADO ACOPILE	LADO EMPUJE	LADO ACOPILE	LADO EMPUJE	LADO ACOPILE	LADO EMPUJE				
																														psi	psi	BPD	° F
10/07/2017	21	165		110478.25	590.44	50.04		122.21	133.22	130	115	332	210	0.0267	0.03	0.35	0.22	0.36	0.51	1797	33	152	140	145	150			35	145.4	150	155		
10/07/2017	21	165		111146.15	591.44	49.99		120.41	126.90	123	120	335	200	0.03	0.02	0.36	0.25	0.36	0.49	1796	35	145.4	150	150	156			35	145.4	150	150	156	
11/07/2017	21	165		110956.34	589.57	49.90		116.51	119.42	123	115	335	200	0.0013	0.0075	0.3642	0.2136	0.3604	0.566	1800	34	140	150.8	152.6	158			34	140	150.8	152.6	158	
12/07/2017	21	150		111232.20	589.56	50.09		122.57	128.06	125	110	332	200	0.03	0.025	0.38	0.23	0.36	0.54	1793	34	143.6	143.8	147.2	154.4			35	140	141	145	154	
12/07/2017	20.5	165		111751.65	589.18	49.88		116.52	123.23	125	112	335	200	0.0328	0.0275	0.37	0.22	0.32	0.5	1799	34	136.4	147.2	150.8	156			35	140	141	145	154	
13/07/2017	20.5	165		112246.73	588.36	49.94		121.75	126.17	125	115	345	200	0.03	0.03	0.39	0.22	0.36	0.54	1797	35	138	145	149	154			35	138	145	149	154	
13/07/2017	21	140		111460.91	585.45	50.04		116.21	125.81	125	114	345	200	0.029	0.0244	0.3281	0.2002	0.3396	0.3471	1799	35	140	141	145	154			35	140	141	145	154	
15/07/2017	21	150		108693.89	586.12	49.94		117.62	123.81	125	118	338	200	0.0237	0.023	0.35	0.24	0.34	0.53	1799	35	145	145	149	154			35	145	145	149	154	
16/07/2017	20.5	150		108449.67	590.75	50.02		130.40	131.90	125	120	338	190	0.02	0.025	0.37	0.21	0.38	0.51	1799	35	145.4	145.4	149	154.4			35	145.4	145.4	149	154.4	
16/07/2017	20.5	165		108413.93	591.50	50.00		126.52	130.03	125	116	338	200	0.02	0.02	0.32	0.31	0.02	0.38	0.58	1797	35	145.4	149	150	156			35	145.4	149	150	156
17/07/2017	21	150		108579.47	591.67	50.00		101.61	108.53	130	132	340	195	0.02	0.0305	0.3566	0.2269	0.3584	0.578	1793	35	147.2	154	159	160			35	147.2	154	159	160	
17/07/2017	20.5	165		109402.83	592.26	50.03		1.50	2.03	135	127	338	200	0.02	0.02	0.38	0.2	0.35	0.53	1799	36	136.4	147.2	150.8	156			36	136.4	147.2	150.8	156	
18/07/2017	20.5	165		110884.21	594.42	49.91		0.25	-1.19	120	115	330	200	0.02	0.02	0.31	0.21	0.35	0.55	1797	36	138	145	149	154			36	138	145	149	154	
18/07/2017	20	168		111898.58	596.12	49.93		-0.03	-1.46	128	125	338	200	0.025	0.034	0.31	0.22	0.38	0.57	1799	35	140	141	145	154			35	140	141	145	154	
19/07/2017	21	165		112445.94	595.19	50.14		0.97	-1.28	125	130	340	200	0.02	0.0313	0.3004	0.2357	0.351	0.5417	1797	35	140	145.4	147.2	154.4			35	140	145.4	147.2	154.4	
19/07/2017	20.5	167		112441.26	595.07	50.08		1.02	-0.51	127	115	338	190	0.0305	0.03	0.31	0.22	0.36	0.55	1800	35	145	145.4	147.2	154.4			35	145	145.4	147.2	154.4	
20/07/2017	20	165		111894.66	589.02	49.80		1.09	-1.09	124	120	340	190	0.031	0.028	0.31	0.21	0.39	0.57	1800	35	145	145	149	154			35	145	145	149	154	
20/07/2017	21	164		111046.01	592.14	51.10		0.99	-1.70	130	130	340	190	0.02	0.0305	0.3261	0.2231	0.3528	0.545	1799	35	145	143.6	145.4	154.4			35	145	143.6	145.4	154.4	
21/07/2017	21	165		109925.22	592.30	51.69		1.05	-1.46	132	125	335	200	0.02	0.0328	0.32	0.222	0.39	0.58	1799	34	145.4	145.4	149	154.4			34	145.4	145.4	149	154.4	
21/07/2017	21	164		110116.85	591.63	51.68		1.04	-1.47	125	125	340	200	0.02	0.03	0.33	0.24	0.38	0.57	1798	33	145.4	149	150	156			33	145.4	149	150	156	
22/07/2017	20.5	170		111621.13	591.26	51.76		1.11	-1.06	126	126	340	190	0.02	0.034	0.31	0.24	0.39	0.51	1799	32	147.2	154	159	160			32	147.2	154	159	160	
22/07/2017	21	165		112407.49	587.55	51.71		1.07	-1.28	125	140	340	190	0.025	0.0305	0.3052	0.2116	0.3833	0.5895	1797	31	147.2	143.6	145.4	154.4			31	147.2	143.6	145.4	154.4	
23/07/2017	20.5	157		112475.68	590.69	51.76		1.12	-0.99	132	150	340	195	0.02	0.0282	0.32	0.22	0.38	0.59	1796	30	136.4	150.8	152.6	158			30	136.4	150.8	152.6	158	
23/07/2017	21	165		112528.10	587.59	51.72		1.07	-1.31	125	125	340	195	0.0305	0.038	0.32	0.21	0.39	0.55	1799	33	141	147	149	156			33	141	147	149	156	
24/07/2017	20.5	165		113764.84	588.00	51.76		1.12	-0.96	107	104	338	190	0.025	0.0313	0.35	0.21	0.39	0.55	1800	34	140	152	152	158			34	140	152	152	158	
24/07/2017	21	165		113962.05	586.65	51.69		1.09	-1.21	132	137	340	200	0.025	0.0321	0.3566	0.2213	0.38	0.53	1793	35	136.4	152	152	158			35	136.4	152	152	158	
25/07/2017	21	165		113528.60	586.13	51.66		1.12	-0.97	125	115	338	200	0.0305	0.02	0.35	0.21	0.36	0.51	1799	36	140	154.4	154.4	158.8			36	140	154.4	154.4	158.8	
14/08/2017	20.5	162		112699.19	589.99	53.67		125.86	123.27	130	143	350	240	0.0237	0.023	0.35	0.24	0.34	0.53	1797	34	145	145	149	154			34	145	145	149	154	
18/08/2017	20.5	165		112853.21	593.71	49.16		129.65	134.95	130	140	330	205	0.02	0.025	0.37	0.21	0.38	0.51	1797	34	145	145	149	154			34	145	145	149	154	
20/08/2017	21	140		112832.88	596.16	48.12		127.89	129.71	125	140	330	205	0.02	0.0305	0.3566	0.2269	0.3584	0.578	1799	35	145.4	145.4	149	154.4			35	145.4	145.4	149	154.4	
6/09/2017	21	150		110484.96	592.12	50.02		122.40	124.31	133	136	340	200	0.025	0.02	0.35	0.21	0.36	0.51	1797	34	145.4	150	150	156			34	145.4	150	150	156	
22/07/2017	21	165		112407.45	587.55	51.71		1.07	-1.28	125	125	340	190	0.025	0.0305	0.3052	0.2116	0.3833	0.5895	1797	31	147.2	143.6	145.4	154.4			31	147.2	143.6	145.4	154.4	
24/07/2017	21	165		113962.05	586.65	51.69		1.09	-1.21	132	137	340	200	0.025	0.0321	0.3566	0.2213	0.38	0.53	1793	35	136.4	152	152	158			35	136.4	152	152	158	
13/08/2017	20	145		118276.99	580.51	50.79		1.13	-1.30	130	136	360	200	0.0252	0.0237	0.36	0.22	0.34	0.49	1797	35	138	145	149	154			35	138	145	149	154	
19/08/2017	20	165		116862.90	580.90	50.76		1.16	-1.15	127	127	330	200	0.0252	0.0237	0.36	0.22	0.34	0.49	1799	35	140	145.4	147.2	154.4			35	140	145.4	147.2	154.4	
19/08/2017	21	0		118941.55	582.24	50.75		1.11	-1.54	130	150	330	180	0.0237	0.023	0.35	0.24	0.34	0.53	1797	36	145	145.4	147.2	154.4			36	145	145.4	147.2	154.4	
24/12/2017	21	165		120284.65	591.08	51.67		126.75	128.08	135	140	330	200	0.025	0.0313	0.35	0.21	0.39	0.55	1793	35	147.2	154	159	160			35	147.2	154	159	160	
1/03/2018	20	165		117058.88	595.85	50.03		127.52	134.21	115	115	143	330	0.03	0.02	0.36	0.25	0.36	0.49	1799	34	145	143.6	145.4	154.4			34	145	143.6	145.4	154.4	
10/04/2018	20	164		120398.40	580.35	50.01		120.62	130.97	135	140	327	2																				

Anexo I. Datos Modo de Falla Parada inesperada.

FECHA	PROCESO										SISTEMA DE SELADO 21/53B										VIBRACIONES										VELOCIDAD	CORRIENTE	TEMPERATURAS			
	PRESION		FLUJO TOTAL	TEMPERATURA		NIVEL	PRESION		PRESION		TEMP SELLO	TEMP SELLO	TEMP FLUSHING	TEMP FLUSHING	MOTOR		BOMBA						MOTOR	MOTOR	MOTOR		BOMBA									
	SUCCION	DESCARGA		SUCCION	TORRE		LADO ACOPILE	LADO EMPUJE	LADO ACOPILE	LADO EMPUJE					LADO ACOPILE	LADO EMPUJE	LADO ACOPILE	LADO EMPUJE	LADO ACOPILE	LADO EMPUJE	MIL	MIL			MIL	MIL	RPM	AMP	LADO EMPUJE	LADO ACOPILE			LADO ACOPILE	LADO EMPUJE		
																																			psi	psi
2/11/2017	21	168	17062.83	592.48	50.04		119.17	123.66	125	115	300	200	0.031	0.028	0.31	0.21	0.39	0.57	1797	33			145.4	149	150	156										
3/11/2017	20	168	14282.21	481.58	50.00		115.17	120.68	130	125	300	200	0.02	0.0305	0.3261	0.2231	0.1928	0.545	1799	34			147.2	154	159	160										
3/11/2017	21	166	29005.89	490.84	50.01		128.61	127.64	132	113	300	200	0.02	0.0328	0.32	0.222	0.39	0.58	1797	35			147.2	143.6	145.4	154.4										
4/11/2017	20	168	70044.15	602.12	49.99		139.25	138.62	127	115	330	200	0.02	0.03	0.33	0.24	0.38	0.57	1793	36			136.4	150.8	152.6	158										
4/11/2017	20	166	15991.57	600.52	50.01		130.90	128.35	126	115	330	200	0.025	0.02	0.35	0.21	0.36	0.51	1799	33			141	147	149	156										
5/11/2017	19	169	99996.54	597.95	50.02		129.81	129.45	130	125	307	190	0.02	0.03	0.39	0.22	0.36	0.54	1797	34			140	152	152	158										
5/11/2017	20	168	104753.14	596.96	50.00		126.16	124.70	125	120	308	200	0.029	0.0244	0.3281	0.2002	0.3396	0.3471	1799	34			136.4	152	152	158										
13/01/2018	20	164	100828.58	605.71	49.98		135.43	121.78	130	120	325	210	0.0252	0.0237	0.36	0.22	0.34	0.49	1793	34			143	152	152	158										
13/01/2018	20	165	99887.66	607.54	50.00		133.83	124.95	130	120	325	200	0.0237	0.023	0.35	0.24	0.34	0.53	1799	34			140	150.8	152.6	158										
19/05/2018	21	164	90796.38	580.23	50.03		122.39	121.39	125	120	330	205	0.02	0.03	0.39	0.22	0.36	0.54	1799	33			140	141	145	154										
20/05/2018	20	165	102971.69	580.08	50.04		152.23	25.27	130	130	321	205	0.029	0.0244	0.3281	0.2002	0.3396	0.3471	1797	35			140	145.4	147.2	154.4										
20/05/2018	20	164	66.09	321.20	50.05		21.01	1.30	130	120	321	200	0.029	0.244	0.396	0.2403	0.3757	0.3777	1793	34			145	145.4	147.2	154.4										
21/05/2018	20	165	84.11	267.90	50.00		26.90	4.70	130	125	320	200	0.0252	0.0237	0.36	0.22	0.34	0.49	1799	34			145	145	149	154										
21/05/2018	20.5	164	63.07	193.11	50.01		23.72	2.53	124	120	323	205	0.0237	0.023	0.35	0.24	0.34	0.53	1797	34			145	143.6	145.4	154.4										
22/05/2018	20.5	165	62.86	135.09	49.97		25.62	3.02	130	125	325	200	0.02	0.025	0.37	0.21	0.38	0.51	1799	34			145.4	145.4	149	154.4										
22/05/2018	22	164	63.02	111.64	50.02		21.82	2.05	128	120	323	195	0.02	0.02	0.31	0.02	0.38	0.58	1797	35			145.4	149	150	156										
23/05/2018	20	165	63.54	134.31	49.99		22.96	3.23	130	125	325	195	0.02	0.0305	0.3566	0.2209	0.3584	0.578	1793	35			147.2	154	159	160										
23/05/2018	21	165	62.36	109.75	50.06		18.19	1.24	120	120	320	200	0.02	0.02	0.38	0.2	0.35	0.53	1799	35			136.4	147.2	150.8	156										
24/05/2018	21	165	61.88	97.05	50.00		18.21	1.73	125	125	340	210	0.0305	0.038	0.32	0.21	0.39	0.55	1797	34			138	145	149	154										
24/05/2018	21	164	63.52	105.03	50.02		16.75	1.40	124	120	325	220	0.35	0.0313	0.35	0.21	0.39	0.55	1799	35			140	141	145	154										
25/05/2018	21	164	68.08	97.27	50.00		17.85	2.56	112	116	328	210	0.39	0.0321	0.3566	0.2213	0.38	0.53	1797	35			140	145.4	147.2	154.4										
25/05/2018	21	164	69.14	90.19	50.00		15.18	0.59	120	117	325	220	0.025	0.02	0.35	0.21	0.36	0.51	1800	35			145	145.4	147.2	154.4										
26/05/2018	21	164	66.70	89.56	50.01		16.11	2.34	125	115	325	210	0.02	0.03	0.39	0.22	0.36	0.54	1800	35			145	145	149	154										
26/05/2018	21	164	15516.64	88.90	50.01		13.17	0.67	125	107	330	210	0.029	0.0244	0.3281	0.2002	0.3396	0.3471	1799	35			145	143.6	145.4	154.4										
27/05/2018	20.7	162	66402.89	156.01	50.02		12.74	1.74	125	125	330	210	0.029	0.244	0.396	0.2403	0.3757	0.3777	1799	36			145.4	145.4	149	154.4										
27/05/2018	21	165	75815.34	467.22	50.02		10.94	1.25	120	125	321	220	0.0252	0.0237	0.36	0.22	0.34	0.49	1798	36			145.4	149	150	156										
28/05/2018	22	164	103701.34	596.74	50.03		10.35	1.71	125	125	321	200	0.0237	0.023	0.35	0.24	0.34	0.53	1799	35			147.2	154	159	160										
22/08/2018	21.5	162	103834.51	561.77	50.59		128.84	128.26	115	115	330	200	0.031	0.028	0.31	0.21	0.39	0.57	1799	34			145	145	149	154										
22/08/2018	20.5	162	103546.83	582.12	50.63		127.82	126.67	120	120	321	210	0.02	0.0305	0.3261	0.2231	0.1928	0.545	1799	34			145	143.6	145.4	154.4										

Anexo J. Planes de gestión.

CODIGO ISO 14224	MODOS DE FALLA	COMPONENTE AFECTADO	ESTRATEGIA	TAREA	FRECUENCIA	ALCANCE	EJECUTOR
ELU	Fuga externa medio auxiliar (perdida liquido barrera)	SELLO MECANICO	Preventiva	Ajuste presion liquido barrera	Por condicion	Ajuste presion liquido barrera con sistema hidraulico	Operador del area
ELP	Fuga externa medio de proceso (fuga diesel)			Ajuste presion N2 vejiga	Trimestral	Verificar y/o Ajustar presion de N2 en la vejiga	Mantenimiento
INL	Fuga interna (perdida liquido barrera)			Cambio total liquido barrera	Semestral	Drenar y cambiar liquido barrera	Mantenimiento
		Por condicion	Reparacion general del sello	Por condicion	Mantenimiento de sellos en taller	Mantenimiento	
OHE	Sobrecalentamiento (sistema de sello y flushing)	ENFRIADORES SISTEMA DE SELLO Y FLUSHING	Preventiva	Retrolavado del enfriador	Mensual	Realizar retrolavado a enfriadores	Operador del area
PDE	Desviacion deparámetros (temperatura y presion)			Limpieza mecanica	Trimestral	Realizar limpieza con hidrojet	Mantenimiento
PLU	Taponamiento/Restringido (enfriadores sello)			Prueba hidrostatica	Trimestral	Realizar prueba hidrostatica para descartar daños en material	Mantenimiento
		Por condicion	Cambio total del serpentín	Por condicion	Reemplazar serpentín por daño	Mantenimiento	
NOI	Ruido	RODAMIENTOS EJE IMPULSOR		Analisis/Cambio de aceite		Realizar chequeo de estado de aceite. Enviar muestra para analisis Cambiar según condicion	Operador
BRD	Rotura (eje)			Alineacion conjunto motor-bomba	Semestral	Verificar / Ajustar alineacion con laser	Mantenimiento
				Termografias	Semestral	Realizar termografias a rodamientos del motor y bomba	Mantenimiento
			Por condicion	Cambio de rodamientos	Por condicion	Reemplazo de rodamientos	Mantenimiento
				Cambio eje		Reemplazo del eje, balanceo y alineacion del conjunto	Mantenimiento
UST	Parada inesperada	EJE o IMPULSOR	Por condicion	Cambio de rodamientos	Por condicion	Cambio de rodamientos por falla	Mantenimiento
			Preventiva	Monitoreo vibraciones	Quincenal	Realizar monitoreo con CSI	Operador
		MOTOR	Preventiva	Monitoreo vibraciones	Quincenal	Realizar monitoreo con CSI	Operador
				Analisis/Cambio de aceite	Quincenal	Realizar chequeo de estado de aceite. Enviar muestra para analisis Cambiar según condicion	Operador
				Pruebas electricas	Semestral	Pruebas electricas al motor (Aislamiento, TTR)	Mantenimiento
			Preventiva	Mantenimineto General	Quinquenal	Mantenimiento general en taller	Mantenimiento