

**CONTENIDO DE AZUFRE EN EL ACPM HIDROTRATADO DE LA REFINERÍA
DE BARRANCABERMEJA: PREDICCIÓN CON REDES NEURONALES Y
PROPORCIONES PARA LA PREPARACIÓN DE DIESEL COMERCIAL**

CRISTIAN EDUARDO SIERRA BALLESTEROS

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISCOQUÍMICAS
ESCUELA DE INGENIERÍA QUÍMICA
MAESTRÍA EN INGENIERÍA QUÍMICA
BUCARAMANGA**

2017

**CONTENIDO DE AZUFRE EN EL ACPM HIDROTRATADO DE LA REFINERÍA
DE BARRANCABERMEJA: PREDICCIÓN CON REDES NEURONALES Y
PROPORCIONES PARA LA PREPARACIÓN DE DIESEL COMERCIAL**

CRISTIAN EDUARDO SIERRA BALLESTEROS

Proyecto para optar por el título de Magíster en Ingeniería Química

Director

FREDY AUGUSTO AVELLANEDA VARGAS

Ph D. en Ingeniería Química

Codirector

GIOVANNI MORALES MEDINA

Ph D. en Ingeniería Química

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISCOQUÍMICAS
ESCUELA DE INGENIERÍA QUÍMICA
MAESTRÍA EN INGENIERÍA QUÍMICA
BUCARAMANGA**

2017

DEDICATORIA

Este trabajo de aplicación está dedicado a Dios porque me ha dado el conocimiento, la sabiduría y la paciencia para enfrentar nuevos retos.

A mi esposa Eliana, a mis hijos Cristian David, Samuel y Sara por su comprensión y acompañamiento durante este camino de estudio.

A mis padres y hermanos que han sido un apoyo constante en este proceso. Los amo mucho.

Cristian Eduardo Sierra Ballesteros

AGRADECIMIENTOS

Quiero agradecer a la Empresa Colombiana de Petróleos ECOPETROL S.A. que representada por sus funcionarios Orlando Díaz Montoya, Ernesto Gómez Cabarcas y Liliana Patricia Angulo confiaron en mis capacidades y me dieron esta oportunidad de crecer profesionalmente con el objetivo hacer más grande esta empresa a través del conocimiento con proyectos de alto impacto en la Gerencia Refinería de Barrancabermeja.

A mis compañeros de estudio por su espíritu de colaboración y apoyo en los momentos de mayor reto y exigencia.

Al ingeniero German Castellanos Romero y los PhD Fredy Avellaneda Vargas y Giovanni Morales Medina, que durante todo el proceso de elaboración de este trabajo de aplicación me guiaron con sus conocimientos técnicos y sabios consejos.

Finalmente, a Dios y a mi familia por su incondicional apoyo y constante amor.

TABLA DE CONTENIDO

	Pág.
INTRODUCCIÓN	19
1. MARCO TEÓRICO	22
1.1. SECCIÓN DE MEZCLA O BLENDING DE DIÉSEL	22
1.2. OPTIMIZACIÓN DE LA MATRIZ DE MEZCLA	25
1.3. UNIDAD DE HIDROTRATAMIENTO U-4700	27
1.4. MODELOS DE PREDICCIÓN DE LA REMOCIÓN DE AZUFRE	29
1.5. REDES NEURONALES	32
1.6. PROPÓSITO DEL PRESENTE TRABAJO	43
2. METODOLOGÍA	45
2.1. REVISIÓN BIBLIOGRÁFICA Y RECOPIACIÓN DE DATOS	45
2.2. SIMULACIÓN DE HIDROTRATAMIENTO Y MEZCLADO DE DIÉSEL	46
2.3. ANÁLISIS ESTADÍSTICO DE DATOS	49
2.4. DESARROLLO DE LA RED NEURONAL	50
2.4.1. Diseño y arquitectura de las redes neuronales	50
2.4.2. Entrenamiento de la red neuronal	51
2.4.3. Validación de las redes neuronales	51
2.5. MODELO DE OPTIMIZACIÓN DE BLENDING	51
3. SIMULACIÓN EN HYSYS DEL SISTEMA HDT-BLENDING	52
3.1. SIMULACIÓN UNIDAD HDT	52
3.1.1. Análisis de sensibilidad para la composición del crudo	58
3.2. SIMULACIÓN SECCIÓN DE MEZCLA (BLENDING)	63
3.3. ACOPLADO PROCESO HDT Y SECCIÓN DE BLENDING	65

4. DESARROLLO Y VALIDACIÓN DE UNA RED NEURONAL.....	71
4.1. SELECCIÓN DE DATOS HISTÓRICOS DE ESTADO ESTACIONARIO	71
4.2. RNA PARA EL ACPM HIDROTRATADO Y SU CONTENIDO DE AZUFRE ..	73
4.3. RNA PARA LAS CONDICIONES DE OPERACIÓN	78
4.4. RNA PARA LA PREDICCIÓN DE VARIABLES INDIVIDUALES	82
4.5 PRUEBAS DE VALIDACIÓN ADICIONALES	84
5. MODELO MATEMÁTICO DE OPTIMIZACIÓN	97
5.1. ÍNDICES DE MEZCLA	97
5.2. RUTEO DE LOS COMPONENTES	97
5.3. MODELO MATEMÁTICO.....	99
5.4 EVALUACIÓN DEL MODELO PROPUESTO	105
5.5. EVALUACION ADICIONAL AL MODELO DE OPTIMIZACION	112
6. IMPACTO DE LOS RESULTADOS DEL PRESENTE TRABAJO.....	118
6.1. IMPACTO EN HDT	119
7. CONCLUSIONES	123
8. RECOMENDACIONES.....	124
REFERENCIAS BIBLIOGRÁFICAS.....	125
BIBLIOGRAFÍA	129
ANEXOS	133

LISTA DE FIGURAS

	Pág.
Figura 1. Diagrama representativo de la matriz de blending.....	23
Figura 2. Grafica Potencial económico por destilación del diésel.	26
Figura 3. Potencial económico por contenido de azufre (ppm) en el diésel.	26
Figura 4. Arquitectura de una red neuronal.	34
Figura 5. Funciones de activación habituales.	35
Figura 6. Esquema de la metodología	45
Figura 7. Árbol de decisión para la escogencia de modelo termodinámico.	48
Figura 8. Diagrama de esquema de la simulación de hidrotratamiento de diesel en GRB	49
Figura 9. Diagrama de una unidad de refinación de crudo donde se obtiene cada corriente de ACPM.....	54
Figura 10. Intercambiadores y reactores codificados en HYSYS para la unidad HDT.	55
Figura 11. Tendencia histórica de contenido de azufre total en la carga a HDT ...	55
Figura 12. Cambios en la composición de azufre en el acpm cargado en HDT por variación del porcentaje de crudo LCT destilado en la U-250, según simulaciones.	56
Figura 13. Cambios en el contenido de azufre hidrotratado vs cambios en la carga de crudo.	59
Figura 14. Cambio en los valores de T95 del acpm hidrotratado según carga de crudo LCT a unidades de destilación.	60
Figura 15. Variación en la temperatura de los reactores y en el contenido de azufre del acpm hidrotratado según la dosificación de crudo acido.....	61
Figura 16. Conversión de crudo Nare y LCT en productos destilados.....	61

Figura 17. Cambio en la destilación del acpm (T95%) de acuerdo al porcentaje de crudo ácido cargado en destilación.....	62
Figura 18. Curvas TBP de crudo Nare y LCT	63
Figura 19. Diagrama de dispersión para el punto final de ebullición (PFB).	73
Figura 20. Variación del MSE con N durante la validación en la predicción del HC2 y S2 con redes FA-I	76
Figura 21. Variación del R ² con N durante la validación en la predicción del HC2 y S2 con redes FA-II	76
Figura 22. Modelo de RNA planteado por Arce <i>et al.</i>	77
Figura 23. Variables de entrada y salida, modelos de RNA propuestos por Lukec <i>et al.</i>	77
Figura 24. Variación de R ² vs N en las redes FA-I para la predicción de H, dT y P.....	80
Figura 25. Variación de R ² vs N en las redes FA-II para la predicción de H, dT y P.....	80
Figura 26. Variación de MSE vs N en las redes FA-I para la predicción de H, dT y P.....	80
Figura 27. Variación de MSE vs N en las redes FA-II para la predicción de H, dT y P.	81
Figura 28. Diagrama de dispersión para el flujo de hidrógeno (H) en la validación extra	85
Figura 29. Diagrama de dispersión para el cambio de temperatura en la zona de reacción (dT) en la validación extra	85
Figura 30. Gráfica de los scores para los dos primeros componentes principales. Los diferentes símbolos y colores representan las clases obtenidas por el método k-mean considerando la distancia euclidiana	91
Figura 31. Variación del punto inicial de ebullición vs el flujo de carga; las clases se indican con los diferentes símbolos y colores obtenidas por el método k-mean considerando la distancia euclidiana	92
Figura 32. Proyección de operación de la unidad de hidrotatamiento	120

Figura 33. Tendencia de azufre (ppm) en preparación de diésel.....	121
Figura 34. Tendencia de destilación de preparaciones de diésel final.....	121
Figura 35. Tendencia de proceso de ajuste de variable de azufre del controlador DMC PLUS unidad de hidrot ratamiento	122
Figura 36. Esquema RNA para la predicción del flujo de ACPM hidrot ratado y su contenido de azufre.....	133
Figura 37. Esquema RNA para la predicción del flujo de hidrógeno, cambio de temperatura y presión en la zona de reacción.	134
Figura 38. Esquema RNA para la predicción del flujo de hidrógeno y cambio de temperatura en la zona de reacción.....	134
Figura 39. Gráfica del R2 vs en número de neuronas en la capa oculta para la predicción del H y dT. Redes neuronales con función de activación FA I.....	136
Figura 40. Gráfica del R2 vs en número de neuronas en la capa oculta para la predicción el H y dT. Redes neuronales con función de activación FA II.....	136
Figura 41. Gráfica del MSE vs en número de neuronas en la capa oculta para la predicción del H y dT. Redes neuronales con función de activación FA I.....	136
Figura 42. Gráfica del MSE vs en número de neuronas en la capa oculta para la predicción del H y dT. Redes neuronales con función de activación FA II.....	137
Figura 43. Esquema RNA para la predicción del flujo del contenido de azufre en HC2.....	138
Figura 44. Esquema RNA para la predicción del flujo de ACPM hidrot ratado.	138
Figura 45. Esquema RNA para la predicción de la relación ACPM/hidrógeno	139
Figura 46. Esquema RNA para la predicción del flujo hidrógeno.....	139
Figura 47. Esquema RNA para la predicción del cambio de temperatura en la zona de reacción.....	140
Figura 48. Diagrama de dispersión para el flujo de ACPM (HC1)	141
Figura 49. Diagrama de dispersión para el punto final de ebullición (PFB).	141
Figura 50. Diagrama de dispersión para grados API.	141
Figura 51. Diagrama de dispersión para el contenido de azufre en HC1 (S1).....	142
Figura 52. Diagrama de dispersión para el flujo de hidrógeno (H).....	142

Figura 53. Diagrama de dispersión para la relación ACPM/hidrógeno (RR).....	142
Figura 54. Diagrama de dispersión para la temperatura de entrada (T1).	143
Figura 55. Diagrama de dispersión para el cambio de temperatura en la zona de reacción (dT).....	143
Figura 56. Diagrama de dispersión para la presión de operación en la zona de reacción (P).....	143
Figura 57. Diagrama de dispersión para el flujo de ACPM hidrotratado (HC2)....	144
Figura 58. Diagrama de dispersión para el contenido de azufre en HC2 (S2).	144
Figura 59. Diagrama de dispersión para el punto final de ebullición (PFB) en la validación extra	145
Figura 60 Diagrama de dispersión para grados API en la validación extra.....	145
Figura 61. Diagrama de dispersión para el contenido de azufre en HC1 (S1) en la validación extra	146
Figura 62. Diagrama de dispersión para la relación ACPM/hidrógeno (RR) en la validación extra	146
Figura 63. Diagrama de dispersión para la temperatura de entrada (T1) en la validación extra	146
Figura 64. Diagrama de dispersión para la presión de operación en la zona de reacción (P) en la validación extra	147
Figura 65. Diagrama de dispersión para el flujo de ACPM hidrotratado (HC2) en la validación extra	147
Figura 66. Diagrama de dispersión para el contenido de azufre en HC2 (S2) en la validación extra	147
Figura 67. Diagrama de dispersión para el punto inicial de ebullición (PIB) en la validación extra	148

LISTA DE TABLAS

	Pág.
Tabla 1. Propiedades características de diésel.....	24
Tabla 2. Paquete de Software comerciales utilizados para el desarrollo de redes neuronales.	38
Tabla 3. Recomendaciones para la escogencia del modelo termodinámico	47
Tabla 4. Especificaciones de operación de la Unidad 250.....	53
Tabla 5. Promedios de contenido de azufre (ppm) en el acpm hidrotratado en la ventana de operación.	57
Tabla 6. Tabla ANOVA para la validación del contenido de azufre obtenido por simulación.....	57
Tabla 7. Resultados destilación según datos históricos y simulaciones.	58
Tabla 8. Tabla ANOVA para la verificación de los datos de simulación para la destilación T95% del acpm hidrotratado.	58
Tabla 9. Comparación datos históricos con resultados de simulación para el blending de acpm.....	64
Tabla 10. Análisis de varianza de destilación en blending.....	64
Tabla 11. Tabla comparativa de resultados de blending.....	65
Tabla 12. Comparación de muestras entre azufre real vs simulado en blending...	65
Tabla 13. Análisis de varianza de la dependencia de la preparación de diésel	66
Tabla 14. Resultados operativos en la zona de reacción para mezclas de Blending.....	67
Tabla 15. Tabla de resultados de preparación de diésel con componentes básicos.....	68
Tabla 16. Análisis de la operación de HDT en la simulación con la inclusión de nuevo componente de preparación.....	69
Tabla 17. Resultados con la inclusión de acpm de UNIBON	70

Tabla 18. Resumen de estadísticos para cada variable en la ventana operativa. .	72
Tabla 19. Diagrama de dispersión para el flujo de ACPM (HC1).	73
Tabla 20. Estadísticos para las redes FA-I en la predicción del HC2 y S2.	75
Tabla 21. Estadísticos para las redes FA-II en la predicción del HC2 y S2.	75
Tabla 22. Desempeño de las RNA FA-I en la predicción de H, dT y P.	79
Tabla 23. Desempeño de las RNA FA-II en la predicción de H, dT y P.	79
Tabla 24. Validación de los modelos de red neuronal con funciones de activación FA I.	83
Tabla 25. Validación de los modelos de red neuronal con funciones de activación FA II.	83
Tabla 26. Resumen de las mejores RNA obtenidas.	83
Tabla 27. Resumen de estadísticos utilizados en la validación extra	86
Tabla 28. Resumen estadístico para las variables de operación a baja carga	88
Tabla 29. Rango de operación de la unidad con alto flujo de hidrocarburo	89
Tabla 30. Resumen estadístico de operación a alto flujo y bajo punto inicial de ebullición.	90
Tabla 31. Resumen estadístico de operación a alto flujo y alto punto inicial de ebullición.	90
Tabla 32. Predicción de dT con carga de HC baja.	93
Tabla 33. Predicción de H y dT con carga de HC baja	93
Tabla 34. Predicción de H y dT con carga de HC alta	94
Tabla 35. Predicción de dT con carga de HC alta y bajo PIB	95
Tabla 36. Predicción de dT con carga de HC alta y alto PIB.	95
Tabla 37. Predicción de H y dT con carga de HC alta y alto PIB.	95
Tabla 38. Resultados de los análisis de la preparación real por modelo de optimización	106
Tabla 39. Resultados de laboratorio de la preparación evaluada	107
Tabla 40. Resultados de la preparación evaluados con el modelo de optimización.	108
Tabla 41. Resultados de la matriz de optimización para destilación en 380 ° C. .	109

Tabla 42. Calculo de destilación con valores de T-95 en 370 optimizado	109
Tabla 43. Evaluación de los resultados de preparación sin optimizar.....	110
Tabla 44. Resultados de laboratorio de acuerdo a flujos de preparación.	111
Tabla 45. Resultados de nueva validación de optimización.....	112
Tabla 46. Resultados de preparación inicial	113
Tabla 47. Primera corrida de optimización.....	113
Tabla 48. Segunda corrida de evaluación.....	114
Tabla 49. Segunda corrida para validación de optimización	114
Tabla 50. Tercera Corrida de preparación.	115
Tabla 51. Tercera Corrida de optimización.....	115
Tabla 52. Cuarta Corrida de preparación.....	116
Tabla 53. Cuarta corrida de optimización.	116
Tabla 54. Resultados modelos de redes neuronales con las funciones de activación FA I para la predicción de H y dT.....	135
Tabla 55. Resultados modelos de redes neuronales con las funciones de activación FA II para la predicción de H y dT.....	135
Tabla 56. Corrida 1 preparación normal	149
Tabla 57. Corrida 1 Preparación optimizada.....	150
Tabla 58. Corrida 2 preparación normal	151
Tabla 59. Corrida 2 Preparación Optimizada.....	152
Tabla 60. Corrida 3 preparación normal	153
Tabla 61. Corrida 3 preparación optimizada	154
Tabla 62. Corrida 4 preparación normal	155
Tabla 63. Corrida 4 preparación optimizada	156

LISTA DE ANEXOS

	Pág,
ANEXO A. Esquemas de RNA para la predicción de variables en conjunto.....	133
ANEXO B. Resultados RNA para las condiciones de operación H y dT.....	135
ANEXO C. Esquemas RNA para la predicción de variables individuales.	138
ANEXO D Gráficas de dispersión de las variables del proceso de HDT.....	141
ANEXO E. Gráficas de dispersión de las variables del proceso de HDT. En la validación extra.....	145
ANEXO F. Resultados de evaluación de modelo de optimización.....	149

RESUMEN

TÍTULO: CONTENIDO DE AZUFRE EN EL ACPM HIDROTRATADO DE LA REFINERÍA DE BARRANCABERMEJA: PREDICCIÓN CON REDES NEURONALES Y PROPORCIONES PARA LA PREPARACIÓN DE DIESEL COMERCIAL*

AUTORES: Cristian Eduardo Sierra Ballesteros**

PALABRAS CLAVES: Diésel, biodiesel, Mezcla, Destilación, Azufre, Hidrotratamiento, Redes Neuronales Artificiales (ANN), Optimización.

DESCRIPCIÓN

La preparación de diésel comercial B₂E en la refinería de Barrancabermeja (GRB) debe cumplir los parámetros de calidad comercial y generar rentabilidad para el negocio. Para esto, la sección de mezclado de diésel considera la cantidad de corrientes disponibles y sus respectivas propiedades, especialmente el contenido de azufre del acpm hidrotratado. La disponibilidad del acpm apropiado, envuelve los requerimientos operacionales de hidrotratamiento (HDT). Este trabajo fue dirigido a soportar la operación de mezclado prediciendo las condiciones operativas en HDT y mediante un modelo de optimización establecer una dieta con mayor rentabilidad para el negocio. Datos históricos del proceso fueron utilizados, incluyendo variables de flujo, presión, azufre a la entrada y salida de la unidad, entre otros. Estos fueron utilizados para desarrollar un modelo predictivo de redes neuronales para el hidrotratamiento, según el contenido de azufre del acpm requerido en la preparación de diésel. Los desempeños obtenidos con los modelos por redes neuronales sugieren que es factible ajustar operacionalmente el hidrotratamiento extendiendo el tiempo de corrida de la planta con azufre más acorde a los requeridos en el área de mezclado. Cabe resaltar que los modelos con configuración logsig-purelin en la capa oculta y de salida, arrojaron mejores resultados tanto en entrenamiento como validación para predicción de variables individuales.

Pruebas extras fueron desarrolladas para identificar el comportamiento de la unidad a bajo y alto flujo de carga. Las RNA tienen una capacidad predictora con R² igual a 0,989 para el contenido de azufre en el producto hidrotratado, adicionalmente la utilización de la corriente hidrotratada en el modelo de optimización ofrece una mejor composición en la preparación de diésel.

Las RNA permiten predecir el comportamiento de la unidad de hidrotratamiento de diésel, aunado a la optimización por simulación, son complementos para alcanzar mayor beneficio económico por preparación de diésel para la GRB.

* Trabajo de grado.

** Facultad de Ingenierías Físicoquímicas. Maestría en Ingeniería Química. Director PhD Fredy Avellaneda Vargas. Codirector Giovanni Morales Medina, I.Q., Dr.

ABSTRACT

TITLE: SULPHUR CONTENT IN HYDROTREATED DIESEL OF ARRANCABERMEJA'S REFINERY: PROPORTIONS FOR REGULAR DIESEL BLENDING, PREDICTIONS WITH NEURONAL NETS

AUTHOR: CRISTIAN EDUARDO SIERRA BALLESTEROS**

KEY WORDS: Diesel, biodiesel, blending, distillation, sulphur, hydrotreating artificial neuronal nets (ANN), optimization

ABSTRACT

Regular diesel B₂E preparation at Barrancabermeja's refinery (GRB) must fulfill commercial quality parameters and produce incomes for business. For this, the diesel blending stage consider the available streams quantity and its properties, the sulphur content on Hydro treated diesel specially .appropriate diesel available involves hydro treating operational requirements (HDT), this job was focused to stand the blending operation predicting operational conditions in HDT and to establish a more benefit diet for business by an optimization model. Process historical data was examine, including flow & pressure variables, sulphur content at in/outlet . These items were used to develop a predictive model of neuronal nets for hydro treat according to sulphur concentration of diesel quantity for blending. Neuronal nets performance suggest that it's possible to set the operation of hydro treat delaying running time in sulphur plant more than blending area.

Models with logsig-purelin configuration show best resultants in training as a validity to predict individual variables, extra tests were developed to identify the plant behavior at low & high load flow. Artificial neuronal nets have a predictive skill, where $R^2 = 0.989$ sulphur content of hydro treat product .Overmore using an hydro treat stream on optimization model offer a better composition in a diesel blend.

ANN (artificial neuronal nets) predict the diesel hydro treat unity behavior and optimization by simulation are complements to get the more economical incomes of diesel preparation at Barrancabermeja's refinery

* Project of grade

** Faculty of Physicochemical Engineering. Master's Degree in Chemical Engineering. Director PhD Fredy Avellaneda Vargas. Codirector Giovanni Morales Medina, I.Q., Dr.

INTRODUCCIÓN

Los hidrocarburos derivados del petróleo se constituyen en una fuente de energía utilizada por muchas industrias y como medio energético para el transporte vehicular. Por su característica no renovable, las cantidades de crudos del petróleo disponibles presentan especificaciones de viscosidad elevada y gravedad API baja, lo cual los etiqueta como crudos pesados. Esta denominación de crudos pesados también infiere cantidades bajas de hidrocarburos livianos valiosos, proporciones elevadas de contaminantes como sulfuros, mercaptanos, sales y un contenido elevado de nitrógeno y metales, entre otros [1].

En el proceso de destilación primaria que es la primera etapa para extraerle al crudo los compuestos valiosos se encuentran compuestos con mayor contenido de azufre. A medida que los crudos son más pesados el contenido de azufre también es mayor. Esta condición también impacta en la metalurgia de los equipos de operación al incrementarse la corrosión debido a los compuestos sulfurados.

La tendencia mundial es la producción de combustibles más limpios y amigables con el medio ambiente. Las disposiciones legales así lo requieren y el control que se ejerce por parte de los países cada vez es más estricto. Esta condición ha llevado a las empresas petroleras a utilizar métodos que permitan el retiro o disminución de contaminantes en los productos que generan. Surgen procesos como el hidrotratamiento donde con la utilización de compuestos afines al contaminante se realiza la mayor remoción de los elementos no deseados.

Teniendo en cuenta el estudio realizado por Arango en el año 2009, la calidad de los combustibles en Colombia en las últimas 2 décadas ha tenido un cambio significativo en sus especificaciones. Para el año 1990, el diésel contenía 5000

partes por millón (ppm) de azufre. Para el año 2001 se registra valores de 1200 ppm para Bogotá y 3000 ppm para el resto del país. Posteriormente esta característica se ajustó hasta llegar al año 2012, donde la calidad del diésel estableció valores menores a 50 ppm de azufre para todo el territorio nacional [2]. Este último avance ha sido posible con la entrada en operación de la unidad de hidrotreamiento de diésel y gasolina en la refinería de Barrancabermeja.

La razón fundamental de una empresa de carácter económico, en especial de la industria petrolera además de cuidar de la salud de las personas que trabajan dentro de la organización, el bienestar social y el cuidado del medio ambiente es producir riquezas para sus accionistas y grupos de interés.

Con los cambios que día a día se presentan en materia tecnológica reflejando avances de todo tipo: comercial, empresarial, de desarrollo socio económico, medio ambiental entre otros, las empresas tornan sus procesos para ser a cada momento más competitivos y sostenibles en el mercado, generando valor, siendo responsables con el medio ambiente y generando confianza a través de sus acciones. Todo lo anterior se fundamenta en operar los procesos con excelencia. (Apartes del Marco Estratégico de Ecopetrol).

El desempeño de los procesos y las ventajas competitivas que se logren desarrollar dentro de la industria permite generar mayor rentabilidad y presencia en el mercado.

Dentro de una refinería el proceso de destilación permite transformar la materia prima, en este caso el crudo, en productos de mayor valor económico como gasolina, jet y diésel. Siendo este último un generador de ingresos por la tendencia del incremento de la demanda debido al crecimiento de la economía del país lo cual incurre en el consumo de energía. En primer lugar, para los vehículos

de transporte de carga, transporte masivo o sencillamente para los usuarios que se movilizan en vehículos particulares o producción energética para las factorías.

Los cambios en materia de control de calidad y manejo de hidrocarburos , en especial el diésel presentan oportunidades significativas en el margen de ingresos de la refinería, es por ello que se hace necesario contar con un sistema que permita seguir cumpliendo con las exigencias legales y medio ambientales que están establecidas, y además garantizar la operación de los procesos reduciendo el impacto por reprocesos o por entrega de producto en especificaciones que generan valor económico para la organización. Adicionalmente mantener vínculos de lealtad y compromiso hacia los clientes y en sentido contrario por la satisfacción recibida por la calidad de los productos, la efectividad y oportunidad en la entrega de los mismos.

Actualmente la preparación de diésel presenta oportunidades de mejora en el proceso de extracción de compuestos poco deseados como es el contenido de azufre. Esta propiedad tiene un control específico en el producto final donde su máximo valor debe ser 50 ppm como lo especifica en la tabla 1 y soportado en la resolución 90963 de septiembre de 2014.

1. MARCO TEÓRICO

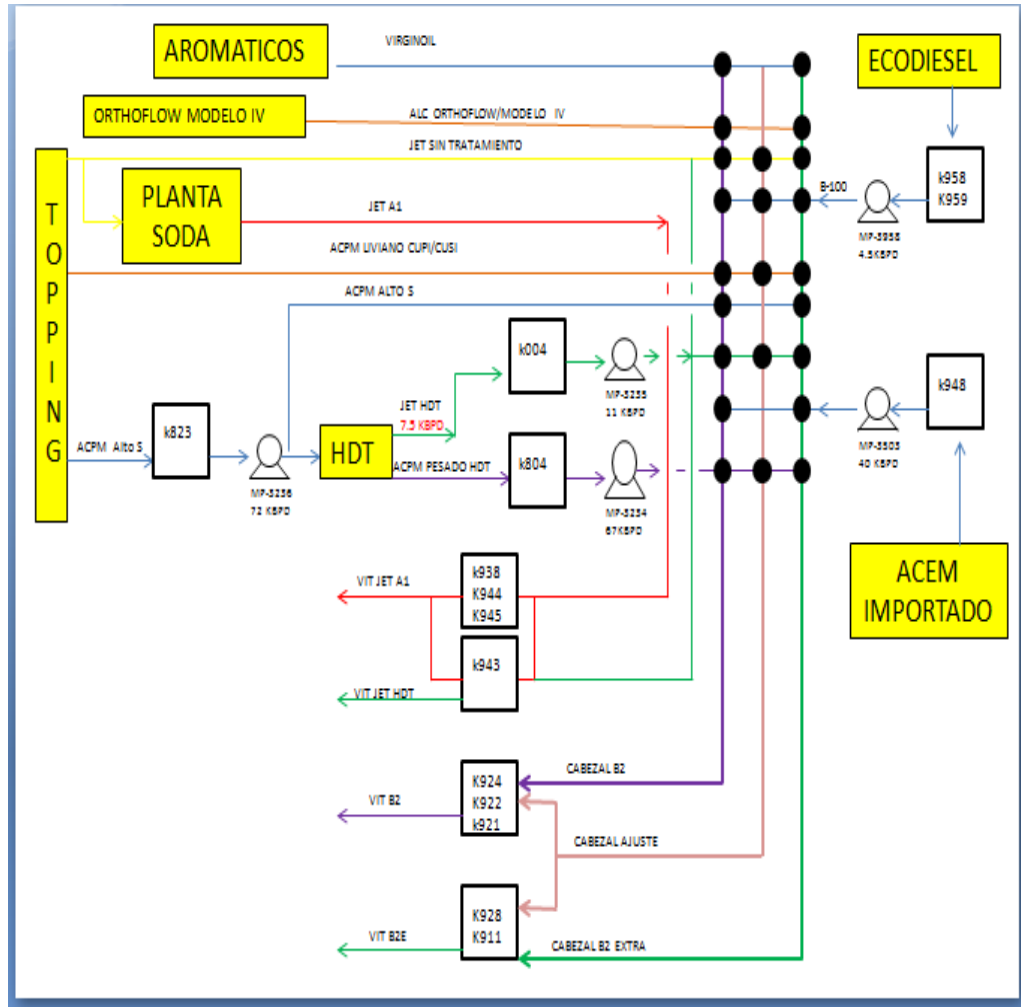
1.1. SECCIÓN DE MEZCLA O BLENDING DE DIÉSEL

En la Gerencia Refinería Barrancabermeja (GRB), se prepara diésel comercial B₂E según la norma colombiana establecida en la resolución 90963 del ministerio de minas y energía [3] ; recibe el nombre de B₂E por el 2% de biodiesel que es adicionado en su composición final. Este producto comercial se genera mediante la utilización de una matriz de mezcla conocida como blending de medios (Figura 1). La matriz de mezcla de diésel es un sistema mecánico en donde los flujos de entrada –provenientes de tanques de almacenamiento o de las plantas de proceso– son enviados a un mezclador en proporciones adecuadas para obtener el producto comercial, ya sea de modo continuo o por lotes dependiendo de los requerimientos definidos en la planeación estratégica de la operación [4].

Las propiedades del diésel B₂E dependen de las proporciones y las características de los flujos utilizados. Estas propiedades pueden ser estimadas utilizando las denominadas reglas de mezcla; en particular, para el contenido de azufre se utiliza la regla de mezcla lineal en peso (i.e. el contenido de azufre del producto final se calcula utilizando los contenidos de azufre y las fracciones en peso de los respectivos flujos en la mezcla), según:

$$Sulf_B = \sum_{i=1}^n x_{w,i} Sulf_i \quad (\text{Ec } 1)$$

Figura 1. Diagrama representativo de la matriz de blending



Fuente Ecopetrol

Las propiedades del diésel B₂E deben satisfacer las especificaciones de calidad requeridas por la normatividad [3] (Tabla 1). Para asegurar la calidad del producto B₂E, diferentes análisis de laboratorio acordes con la normatividad son realizados de forma periódica, lo cual permite aplicar acciones correctivas una vez se presenten desviaciones importantes en alguna propiedad.

Tabla 1. Propiedades características de diésel.

N°	PARAMETRO	UNIDAD	ESPECIFICACIÓN <u>fecha de vigencia</u>	MÉTODO DE ENSAYO
1	Azufre, máximo	% masa	0,005	ASTM D4294
2	Aromáticos, máximo	% Vol.	35 32 (Jul 31 de 2016 en adelante)	ASTM D5186 ó ASTM D1319
3	Número de Cetano, mínimo	—	43 45 Resto País Bogotá	ASTM D613
			45 (Julio 31 de 2016 en adelante)	
4	Índice de Cetano, mínimo	—	45	ASTM D976 ó ASTM D4737
5	Contenido de Biocombustible (máximo)	% Volumen	10	EN 14078
6	Corrosión al cobre, 3h a 50°C, máximo	Clasificación	2	ASTM D130
7	Color ASTM, máximo	—	2	ASTM D1500
8	Destilación	°C	282	ASTM D 86
	Punto inicial de ebullición			
	Temp. 50 % vol. Recobrado			
	Temperatura de 95% volumen recobrado			
Mínimo	360			
Máximo	390			
Punto final de Ebullición.				
Máximo				
9	Punto de inflamación, mínimo	°C	52	ASTM D93
10	Estabilidad a la oxidación	g/m ³	25 máximo	ASTM D2274

Fuente Resolución 90963 de 2014


1.2. OPTIMIZACIÓN DE LA MATRIZ DE MEZCLA

El diésel preparado puede contar con diversos componentes que se encuentran dentro del rango de las especificaciones de mezcla, y que cumplen con los parámetros establecidos para las características del diésel. Ello puede incluir como componente principal acpm y secundarios como naftas pesadas, jet, gasóleo liviano de vacío (GLV), aceite liviano de ciclo (ALC).

Dentro de los componentes principales con los cuales se lleva a cabo la preparación de diésel, existe una corriente de acpm importado, que recibe el nombre de acem. Es un aceite combustible para motor con características de baja destilación y bajo contenido de azufre, satisfaciendo los requerimientos de calidad para el blending de diésel.

Tal como se muestra en la Tabla 1, las especificaciones establecidas en la normatividad colombiana (resolución 0963 de 2014) exigen la preparación de diésel con contenidos de azufre de máximo 50 ppm. Los costos de preparación de diésel tienen incidencia en la economía de la empresa, ya que, especificaciones como destilación y contenido de azufre representan un potencial económico por cada barril producido. Como se aprecia en la Figura 2, variaciones en la destilación al 95% en volumen en el diésel preparado, tiene una disminución económica que incluso puede ser del orden de 0.9 dólares/barril.


Figura 2. Grafica Potencial económico por destilación del diésel.



Fuente Departamento de programación de la producción GRB.

Cambios en el contenido de azufre en el diésel tienen implicaciones en el potencial económico de la preparación. La figura 3 muestra la tendencia económica por cada barril preparado y las incidencias en el margen de refinación por preparaciones de diésel con especificaciones menores a 35 ppm, donde preparaciones por debajo de 20 ppm indican reducción de los ingresos en 2.5 dólares por cada barril de producto.

Figura 3. Potencial económico por contenido de azufre (ppm) en el diésel.



Fuente Departamento de programación de la producción GRB

Lo anteriormente evidenciado refleja oportunidades en los ingresos que deben ser adecuadamente mejoradas y aseguradas en materia económica.

Para cumplir las especificaciones por normatividad claramente definidas y disminuir los regalos económicos por calidad en las preparaciones realizadas en el área de blending, es necesario contar con un proceso de preparación optimizado que aporte al margen de la organización.

1.3. UNIDAD DE HIDROTRATAMIENTO U-4700

El hidrotratamiento es un proceso usado en refinerías para el retiro de compuestos contaminantes de los productos a tratar, en cumplimiento a las normas internacionales en materia ambiental. Esta actividad tiene gran importancia en la industria química y de hidrocarburos debido a la aparición de crudos cada vez más pesados y la necesidad de remoción de compuestos no deseados (azufre, metales, aromáticos, entre otros). El proceso de hidrotratamiento se basa en la reacción de las cargas con el hidrógeno como elemento corrector para el retiro de contaminantes (mercaptanos, sulfuros y disulfuros), en presencia de un catalizador que permita mejorar la reacción. A medida que se incrementa la temperatura de reacción se mejora la remoción de contaminantes en el proceso [5].

En la GRB, la unidad encargada del hidrotratamiento del acpm corresponde a la unidad U-4700. Esta unidad está diseñada para cargar 56600 barriles por día (bpd) de acpm con contenido de azufre entre 3000 y 6000 ppm. Sin embargo, en condiciones de baja carga por condiciones de proceso, puede mantener una operación estable con flujos superiores a 28300 bpd [6]. Las reacciones efectuadas en la unidad realizan una desulfurización profunda generando corrientes de diésel con contenidos de azufre menores a 50 ppm. La U-4700 dispone de dos reactores verticales los cuales constan de 4 lechos catalíticos con

dos tipos de catalizadores: cobalto-molibdeno sobre alúmina y Ni-Mo. Los reactores operan con un rango de temperatura de operación entre 725 y 800 ° F y una presión entre 840 y 950 psig.

Antes de ingresar el acpm virgen con alto contenido de azufre a la unidad de reacción, se une con una corriente de hidrógeno de reciclo y de restitución (*make – up en inglés*), para posteriormente ser precalentado en intercambiador de calor a placas (packinox).

Una temperatura alta en el proceso de precalentamiento mejora las condiciones de ahorro energético del proceso, permitiendo que la operación en el horno sea más favorable y disminuyendo el consumo de gas combustible en el horno.

Acto seguido la carga ingresa al horno que cuenta con 8 serpentines donde se alcanza la temperatura de reacción. La carga combinada de acpm e hidrógeno ingresa al primer reactor distribuyéndose de manera uniforme. En el área de reacción es requerida la inyección de hidrógeno entre los lechos para controlar la temperatura del proceso debido a las reacciones exotérmicas que se presentan en los mismos. Es preciso aclarar que una alta temperatura generará un menor tiempo de corrida por saturación del catalizador, reflejará mayor retiro de contaminantes, pero a la vez mayor encarbonamiento del catalizador, originará incremento en el diferencial de presión en los lechos del reactor y mayor consumo de hidrógeno para la reacción.

Otra condición de proceso que es necesaria controlar dentro de la unidad es la relación hidrógeno / carga, ya que una baja relación, puede generar una desactivación prematura del catalizador, disminuye los tiempos de corrida de la planta, incrementará los depósitos de coque, incrementará la presión diferencial en los lechos de los reactores y originará reacciones desfavorables al proceso. Por otra parte, cuando existe una alta relación hidrógeno / carga, se obtiene un

envejecimiento lento del catalizador y se favorece las condiciones de reacción y remoción de contaminantes, dando lugar a la menor tasa de deposición de coque.

El flujo de hidrógeno de enfriamiento (quench) debe ser controlado en la zona de reacción, ya que un aumento súbito puede ocasionar disminución en las reacciones de hidrotratamiento por baja temperatura en los lechos de reacción. Por otro lado, el bajo flujo de hidrógeno de enfriamiento es detrimento de la vida útil del catalizador, lo que puede llevar a la reducción del flujo de carga de alimentación y disminución del tiempo de corrida en el proceso.

1.4 MODELOS DE PREDICCIÓN DE LA REMOCIÓN DE AZUFRE

Los modelos de predicción de la remoción de azufre en el HDT se han centrado en diversas estrategias, entre ellas se destaca la simulación de los procesos con la ayuda de software que describan el comportamiento y las características de la planta, la bibliografía consultada refiere prueba en plantas piloto para analizar el comportamiento cinético de la reacción. También se aprecia el uso de los datos históricos de las variables de proceso para definir el comportamiento de la unidad y relacionarlo con las condiciones de operación, esto ha permitido obtener mejores resultados en la operación del proceso de hidrotratamiento. Adicionalmente, según se la bibliografía que el uso de redes neuronales en el proceso de hidrotratamiento refleja muy buenos resultados para la predicción de las condiciones de remoción de azufre, condiciones de presión, temperatura y actividad del catalizador.

Algunos trabajos reportados en la literatura son los siguientes:

- Verruschi, 2008, desarrolló una optimización del catalizador en la unidad de hidrotratamiento de destilados medios. En el trabajo se reporta el uso de dos modelos: uno determinístico y el otro estocástico. Como resultado más

relevante se destaca la configuración de los dos tipos de catalizador dentro del reactor al igual que el tamaño del reactor con el fin de disminuir los costos anuales de operación [7].

- Narimani et al, 2015, utilizando el software HYSIS ASPEN realizaron la simulación de una planta de hidrotratamiento de gas con alto contenido de azufre para obtener gas limpio. Los resultados de la simulación mostraron que el gas tratado contendría azufre en cantidades menores de 10 ppm; adicionalmente, la simulación reportó la factibilidad en la remoción del aceite de disulfuro [8] .
- Shokri et al, 2015, desarrollaron una red neuronal para la predicción del parámetro del azufre en el diésel tratado en una unidad de hidrodesulfuración. La red consideró 300 experimentos obteniendo como resultado una predicción para el contenido de azufre con un error medio de 0.0745 y un R^2 de 0.997 [9].
- En el caso local, Álvarez et al., 2012, desarrollaron un modelo experimental para predecir la cinética de la reacción en la unidad de hidrotratamiento de la Refinería de Barrancabermeja. Adicionalmente predijeron las concentraciones de azufre, nitrógeno y aromáticos y compararon sus resultados con la repetibilidad de los métodos de análisis [10]. Este reporte es el único con el que se cuenta para el estudio del HDT en la Gerencia Refinería Barrancabermeja.

La mayoría de los modelos basados en ecuaciones de balance presentan la desventaja de que depende de resultados experimentales de planta piloto para la cinética de la reacción, lo cual puede no corresponder a la presentada en la planta industrial por cuestiones de escalado. Como alternativa, los datos de planta pueden ser empleados para el desarrollo de un modelo de tipo red neuronal para la predicción del comportamiento del equipo industrial [11] , esto permite, basado

en las referencias bibliográficas realizar la evaluación del proceso de hidrotratamiento aprovechando los datos propios de las unidades de proceso.

Entre la evidencia bibliográfica sobre el modelado del proceso de hidrotratamiento en diésel utilizando RNA se tiene:

- Lukec et al. desarrollaron un modelo de predicción de azufre en diésel en un proceso de hidrotratamiento utilizando dos compuestos de cargas. Con la aplicación de RNA obtuvieron que es posible realizar monitoreo continuo, predecir el contenido de azufre y el tiempo de desactivación del catalizador. [12]
- Arce et al, con el uso de redes neuronales modelaron el proceso de hidrodesulfuración de naftas en una refinería de PEMEX utilizando datos históricos de proceso. Los resultados mostraron concordancia con los datos históricos de validación de la RNA [13].

Asimismo, las RNA han sido utilizadas en la predicción de propiedades del diésel utilizando datos espectroscópicos y de propiedades fisicoquímicas:

- Santana et al, 2006, a partir del uso de redes neuronales, analizaron el número de cetano de aproximadamente 147 compuestos y su incidencia en el número de cetano del diésel tradicional. Sus resultados reportan que el diésel preparado con la incorporación de aceite liviano de ciclo tiene efectos negativos en el número de cetano. [14]
- Kumar et al, 2010, mediante el uso de redes neuronales predijeron las propiedades de (punto de inflamación, punto de combustión, viscosidad y densidad) de las mezclas diésel- biodiesel. [15]

- Singh, 2013, utilizó redes neuronales con la filosofía back –propagation, para predecir el comportamiento de un motor diésel, operando con la mezcla de diésel y biodiesel de naranja. Los resultados mostraron precisión con la aplicación de la red neuronal mayores que los obtenidos con algoritmos semi-empíricos [11]
- Sánchez et al, 2014, con ayuda de redes neuronales correlacionaron el índice de cetano y el retardo de ignición de la mezcla diésel- biodiesel de colza y aceite de palma, obteniendo un coeficiente de correlación de 97,2% con un error de 0.03. [16]

1.5. REDES NEURONALES

Según Kohonen, las RNA son redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativos) y con organización jerárquica, las cuales intentan interactuar con los objetos del mundo real del mismo modo que lo hace el sistema nervioso biológico. De otro lado, Hecht y Niesen definen las RNA como un sistema de computación hecho por un gran número de elementos, simples, elementos de proceso muy interconectados, los cuales procesan información por medio de su estado dinámico como respuesta a entradas externas [17]. Estas definiciones presentan las principales características de una RNA las cuales serán mencionadas en los siguientes párrafos

Cuando se desea resolver problemas de difícil solución, se tiene en cuenta las ventajas que ofrecen las redes neuronales, tal como lo menciona Hilera y Martínez en los siguientes enunciados [17]:

“Aprendizaje adaptativo: Esta es quizás la característica más importante de las redes neuronales, pueden comportarse en función de un entrenamiento con una

serie de ejemplos ilustrativos. De esta forma, no es necesario elaborar un modelo a priori, ni establecer funciones probabilísticas. Una red neuronal artificial es adaptativa porque puede modificarse constantemente con el fin de adaptarse a nuevas condiciones de trabajo.

Autoorganización: Mientras que el aprendizaje es un proceso donde se modifica la información interna de la red neuronal artificial, la Autoorganización consiste en la modificación de la red completa con el fin de llevar a cabo un objetivo específico.

Autoorganización significa generalización, de esta forma una red puede responder a datos o situaciones que no ha experimentado antes, pero que puede inferir sobre la base de su entrenamiento. Esta característica es muy útil sobre todo cuando la información de entrada es poco clara o se encuentra incompleta.

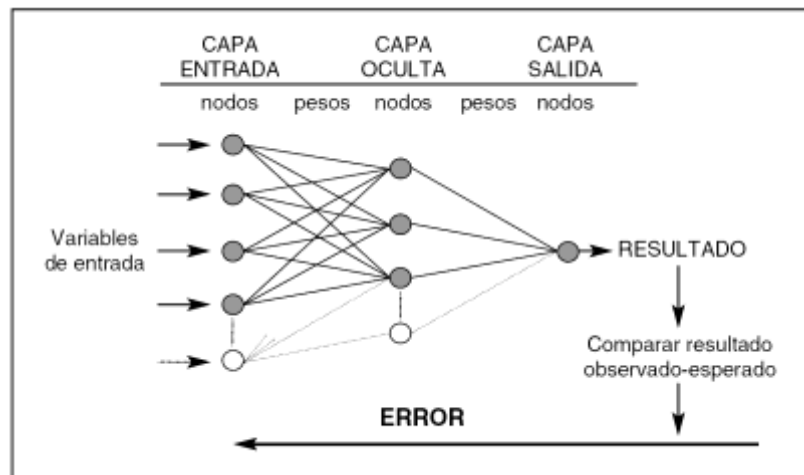
Tolerancia a fallos: En la computación tradicional la pérdida de un fragmento pequeño de información puede acarrear comúnmente la inutilización del sistema. Las redes neuronales artificiales poseen una alta capacidad de tolerancia a fallos. Se entiende por ello que las redes pueden reconocer patrones de información con ruido, distorsión o incompletos, pero que, además, pueden seguir trabajando, aunque se destruya parte de la red (con cierta degradación). La explicación de este fenómeno se encuentra en que mientras la computación tradicional almacena la información en espacios únicos, localizados y direccionables, las redes neuronales lo hacen de forma distribuida y con un alto grado de redundancia.

Operación en tiempo real: Las redes neuronales artificiales, de todos los métodos existentes, son las más indicadas para el reconocimiento de patrones en tiempo real, debido a que trabajan en paralelo actualizando todas sus instancias simultáneamente. Es importante destacar que esta característica solo se aprecia cuando se implementan redes con hardware especialmente diseñados para el procesamiento paralelo.

Fácil inserción en la tecnología existente: Es relativamente sencillo obtener chips especializados para redes neuronales que mejoran su capacidad en ciertas tareas. Ello facilita la integración modular en los sistemas existentes.” [17]

Las RNA están típicamente conformadas por variables de entrada, nodos, capas de entrada, capas ocultas y capas de salida. Cada variable debe tener un peso y cada neurona una función de activación con lo cual se establece la respuesta de salida. La figura 4 muestra el diagrama de una red neuronal artificial [18].

Figura 4. Arquitectura de una red neuronal.



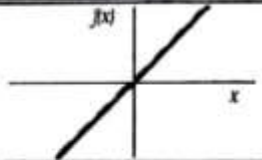
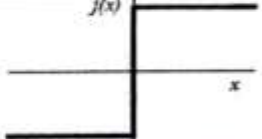
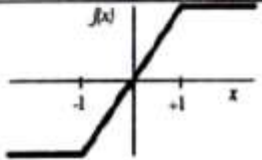

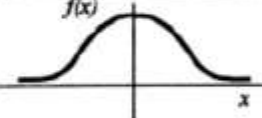

Fuente: Redes neuronales artificiales en Medicina Intensiva. Ejemplo de aplicación con las variables del MPM II

Como lo menciona Hilera et al, en el libro Redes Neuronales Artificiales, pagina 69,

“existen cuatro aspectos que caracterizan una red neuronal: su topología, el mecanismo de aprendizaje, tipo de asociación realizada entre la información de entrada y de salida, y, por último, la forma de representación de estas informaciones” [17]

La figura 5 muestra las funciones de activación más utilizadas en el diseño de redes neuronales. En el caso específico para tratamiento de datos se utilizan las funciones identidad en combinación con el grupo sigmoidea. [19]

Figura 5. Funciones de activación habituales.

	Función	Rango	Gráfica
Identidad	$y = x$	$[-\infty, +\infty]$	
Escalón	$y = \text{sign}(x)$ $y = H(x)$	$\{-1, +1\}$ $\{0, +1\}$	
Lineal a tramos	$y = \begin{cases} -1, & \text{si } x < -l \\ x, & \text{si } -l \leq x \leq +l \\ +1, & \text{si } x > +l \end{cases}$	$[-1, +1]$	
Sigmoidea	$y = \frac{1}{1 + e^{-x}}$ $y = \text{tgh}(x)$	$[0, +1]$ $[-1, +1]$	
Gaussiana	$y = Ae^{-Bx^2}$	$[0, +1]$	
Sinusoidal	$y = A \text{sen}(\omega x + \varphi)$	$[-1, +1]$	

Fuente: (Martín del Brío, 2002).

Las redes neuronales cuentan con una serie de algoritmos de entrenamiento de acuerdo a la tarea a realizar. Se clasifican comúnmente por el tipo de aprendizaje, supervisado y no supervisado. La Tabla 2 muestra la clasificación de los algoritmos de aprendizaje de las diferentes redes neuronales.

El aprendizaje de las redes se basa en la reorganización de los pesos de tal forma que estos que puedan codificar los conocimientos. La regla de aprendizaje hace que los pesos varíen el valor hasta que obtengan un valor constante, cuando este proceso se cumple se dice que la red está entrenada.

En la predicción de datos y especialmente en el caso de hidrotatamiento, la red utilizada, es según la literatura la “back propagation” o retropropagación.

Las redes de retropropagación cuentan con un algoritmo de entrenamiento basado en los mínimos cuadrados, para ello realizan la actualización de los pesos y el ajuste de los mismos en relación al error medio cuadrático. Dado que esta red se entrena bajo un sistema supervisado, requiere de instrucciones que definan la salida y los valores esperados para dicha salida [20] .

Según Guzmán et al, el diseño de una tipología para la red depende del problema a solucionar, donde se tiene en cuenta tres criterios a saber [21]:

- Número de niveles o capas
- Número de neuronas por nivel
- Formas de conexión.

Las redes neuronales tienen como componentes más importantes dentro de su estructura, la unidad de procesamiento, estado de activación de cada neurona, el patrón de conectividad, la regla de propagación, la función de transferencia, la regla de activación y la regla de aprendizaje. [17]

El aprendizaje de la red neuronal requiere del entrenamiento de una cantidad de datos, los cuales se designan como señales de entrada, para los cuales deben tener una señal de salida con un valor correspondiente. El ajuste de los pesos se hace con nuevos datos de entrenamiento y se calcula con el algoritmo de

retropropagación del error. Con cada iteración los pesos se van ajustando conforme se desarrolla el proceso de entrenamiento [20]

Dentro de las aplicaciones tecnológicas que se encuentran disponibles para el desarrollo de redes neuronales se encuentran las definidas en la Tabla 2, mencionando que adicionalmente se pueden desarrollar redes neuronales con paquetes tecnológicos como R, CILAB, ASPEN HYSYS, MATLAB entre otros.

Tabla 2. Paquete de Software comerciales utilizados para el desarrollo de redes neuronales.

Modelo de red	Topología	Aprendizaje			Asociación auto/hetero	Información de entrada y salida	Autor(es)
		On/off line	Supervisado / no supervisado	Regla			
ADALINE/ MADALINE	2 CAPAS Feedforward	OFF	SUPERVIS	CORRECCIÓN ERROR ("LEAST MEAN SQUARE")	HETEROASOC	E: ANALOG S:BINARI	WIDROW HOFF 1960
ADAPTIVE BIDIRECTIONAL ASSOCIATIVE MEMORY. ABAM	2 CAPAS Feedforward/FEED BACK	ON	NO SUPERV	HEBBIANO DIFERENCIAL	HETEROASOC	ANALOG.	KOSKO 1987
ADAPTIVE HEURISTIC CRITIC. AHC	3 CAPAS Feedforward	ON	SUPERVIS.	REFUERZO POR AJUSTE TEMPORAL	HETEROASOC	E: ANALOG S:BINARI	BARTO 1983
ADAPTIVE RESONANCE THEORY 1.ART1	2 CAPAS Feedforward/FEED BACK CONEX. LAT. AUTO-RECU.	ON	NO SUPERV	COMPETITIVO (RESONANCIA ADAPTATIVA)	HETEROASOC	BINARIAS	CARPENTER GROSSBERG 1986
ADAPTIVE RESONANCE THEORY 2.ART2	2 CAPAS Feedforward/FEED BACK CONEX. LAT. AUTO-RECU.	ON	NO SUPERV	COMPETITIVO (RESONANCIA ADAPTATIVA)	HETEROASOC	ANALOG.	CARPENTER GROSSBERG 1987
ADITIVE GROSSBERG. AG	1 CAPA CONEXIONES LATERALES AUTO-RECU.	ON	NO SUPERV	HEBBIANO O COMPETITIVO	HETEROASOC	ANALOG.	GROSSBERG 1968

Modelo de red	Topología	Aprendizaje			Asociación auto/hetero	Información de entrada y salida	Autor(es)
		On/off line	Supervisado / no supervisado	Regla			
ASSOCIATIVE REWARD PENALTY. ARP	2 CAPAS Feedforward	ON	SUPERVIS.	REFUERZO ESTOCÁSTICO	AUTOASOC.	E: ANALOG S:BINARI	BARTO 1985
BACK-PROPAGATION	N CAPAS Feedforward	OFF	SUPERVIS.	CORRECCIÓN ERROR (REGLA DELTA GENERALIZADA)	HETEROASOC	ANALOG.	RUMELHART etc. 1986
RECURRENT BACKPROPAGAT.	N CAPAS FF/F.BACK	OFF	SUPERVIS.	CORRECCIÓN ERROR (REGLA DELTA GENERALIZADA)	HETEROASOC	ANALOG.	PINEDA etc. 1987
BIDIRECTIONAL ASSOCIATIVE MEMORY. BAM	2 CAPAS Feedforward/FEED BACK	ON	NO SUPERV	HEBBIANO	HETEROASOC	BINARIAS	KOSKO 1988
BOLTZMANN MACHINE. BM	1 CAPA CONEX. LAT. 3 CAPAS Feedforward	OFF	SUPERVIS.	ESTOCÁSTICO ("SIMULATED ANNEALING") + HEBBIANO ó + CORRECCIÓN ERROR	HETEROASOC	BINARIAS	HINTON ACKLEY SEJNOWSKI 1984
BRAIN-STATE IN-A-BOX	1 CAPA CONEX. LAT. AUTO-RECU.	OFF	SUPERVIS.	CORRECCIÓN ERROR (REGLA DELTA)	AUTOASOC.	ANALOG.	ANDERSON 1977
CAUCHY MACHINE. CM	1 CAPA CONEX. LAT. 3 CAPAS	OFF	NO SUPERV	ESTOCÁSTICO ("FAST	HETEROASOC	E: ANALOG S:BINARI	SZU 1986

Modelo de red	Topología	Aprendizaje			Asociación auto/hetero	Información de entrada y salida	Autor(es)
		On/off line	Supervisado / no supervisado	Regla			
	Feedforward			SIMULATED ANNEALING")			
COGNITRON/ NEOCOGNITRON	JERARQUIA DE NIVELES CON CAPAS BIDIMENS. FF/F.BACK	OFF	NO SUPERV	COMPETITIVO	HETEROASOC	BINARIAS	FUKUSHIMA 1975/1980
COMPETITIVE ABAM. CABAM	2 CAPAS FF/F.BACK CONEX. LAT. AUTO-RECU.	ON / OFF	NO SUPERV	HEBBIANO + COMPETITIVO	HETEROASOC	ANALOG.	KOSKO 1987
COUNTER-PROPAGATION	3 CAPAS Feedforward CONEX. LAT. y AUTO-RECU.	OFF	SUPERVIS.	CORRECCIÓN ERROR + COMPETITIVO	HETEROASOC	ANALOG.	HECHT-NIELSEN87
DRIVE-REINFORCEMENT	2 CAPAS Feedforward	OFF	NO SUPERV	HEBBIANO (DRIVE REINFORCEMENT)	HETEROASOC	ANALOG.	KLOPF 1986
FUZZY ASSOCIATIVE MEMORY. FAM	2 CAPAS FF/FEEDBACK	OFF	NO SUPERV	HEBBIANO BORROSO	HETEROASOC	ANALOG.	KOSKO 1987
CONTINUOUS HOPFIELD	1 CAPA CONEX. LATERALES	OFF	NO SUPERV	HEBBIANO	AUTOASOC.	ANALOG.	HOPFIELD 1984
DISCRETE HOPFIELD	1 CAPA CONEX. LATERALES	OFF	NO SUPERV	HEBBIANO	AUTOASOC.	BINARIAS	HOPFIELD 1982

Modelo de red	Topología	Aprendizaje			Asociación auto/hetero	Información de entrada y salida	Autor(es)
		On/off line	Supervisado / no supervisado	Regla			
LEARN. MATRIX. LM	1 CAPA CROSSBAR	OFF	NO SUPERV	HEBBIANO	HETEROASOC	BINARIAS	STEINBUCH 1961
LEARNING VECTOR QUANTIZER. LVQ	2 CAPAS FF CONEX. LAT. IMPLIC. AUTORREC.	OFF	NO SUPERV	COMPETITIVO	HETEROASOC	ANALOG.	KOHONEN 1981
LINEAR ASSOCIATIVE MEMORY. LAM	2 CAPAS Feedforward	OFF	NO SUPERV	HEBBIANO	HETEROASOC	ANALOG.	ANDERSON 1968 KOHONEN77
LINEAR REWARD PENALTY. LRP	2 CAPAS Feedforward	ON	SUPERVIS.	REFUERZO ESTOCÁSTICO	HETEROASOC	E: ANALOG S: BINARI	BARTO 1985
OPTIMAL LINEAR ASSOCIATIVE MEMORY. OLAM	2 CAPAS/FF. ----- --- 1 CAPA CONEX. LAT. AUTO-RECU.	OFF	NO SUPERV	HEBBIANO ("OPTIMAL LEAST MEAN SQUARE CORRELATION")	HETEROASOC ----- AUTOASOC.	ANALOG.	WEE 1968 KOHONEN73
PERCEPTRON	2 CAPAS Feedforward	OFF	SUPERVIS.	CORRECCIÓN ERROR	HETEROASOC	E: ANALOG S: BINARI	ROSENBLAT 1958
SHUNTING GROSSBERG. SG	1 CAPA CONEX. LAT. AUTO-RECU.	ON	NO SUPERV	HEBBIANO O COMPETITIVO	AUTOASOC.	ANALOG.	GROSSBERG 1973
SPARSE DISTRIBUTED MEMORY. SDM	3 CAPAS Feedforward	OFF	NO SUPERV	HEBBIANO + RANDOW VECTOR (LVQ) PREPROCESSING	HETEROASOC	BINARIAS	KANERVA 1984

Modelo de red	Topología	Aprendizaje			Asociación auto/hetero	Información de entrada y salida	Autor(es)
		On/off line	Supervisado / no supervisado	Regla			
TEMPORAL ASSOCIAT. MEMORY. TAM	2 CAPAS FF/FEEDBACK	OFF	NO SUPERV	HEBBIANO	HETEROASOC	BINARIAS	AMARI 1972
TOPOLOGY PERSERVING MAP. TPM	2 CAPAS FF CONEX. LAT. IMPLIC. AUTORREC.	OFF	NO SUPERV	COMPETITIVO	HETEROASOC	ANALOG.	KOHONEN 1982

Fuente: Redes Neuronales Artificiales (Hilera J, 2000)

1.6. PROPÓSITO DEL PRESENTE TRABAJO

Cuando una organización define sus objetivos, se centra en razón del mejor y mayor beneficio para sus asociados y grupos de interés. Esto implica la búsqueda de soluciones a diferentes condiciones internas que le permitan solventar las variaciones que le puedan ser adversas por elementos externos a su proceso.

Para ser competitivos es necesario, en primer lugar, lograr un posicionamiento en el mercado que le permita tener solidez. Ello demanda actualización de sus procesos, operar sus unidades de manera eficiente, reducir los reprocesos y sobretodo disminuir los costos innecesarios por manufactura.

El objetivo principal del blending es la preparación de productos dentro de las especificaciones de calidad establecidas, en el tiempo oportuno y en la cantidad requerida por los clientes para cumplir con las necesidades de la cadena de suministro de combustibles de la organización y del país. Actualmente se ha podido evidenciar que el diésel preparado en la GRB, presenta dentro de sus parámetros de calidad, especificaciones en azufre, en partes por millón, muy por debajo de los rangos máximos requeridos, esto a su vez, se refleja en los mayores costos de proceso por mayor incremento de temperatura o flujo de hidrógeno en el área de hidrotratamiento para remoción de contaminantes (azufre) que en términos económicos genera una salida de capital que no rentabiliza en las arcas de la compañía . Razón por la cual una apropiada remoción de azufre, con las condiciones de proceso más acertadas en la unidad de hidrotratamiento y que satisfaga los requerimientos de calidad de la preparación de diésel en el área de blending, permitirá optimizar la mezcla y producción de diésel y rentabilizar un mayor beneficio económico para la compañía.

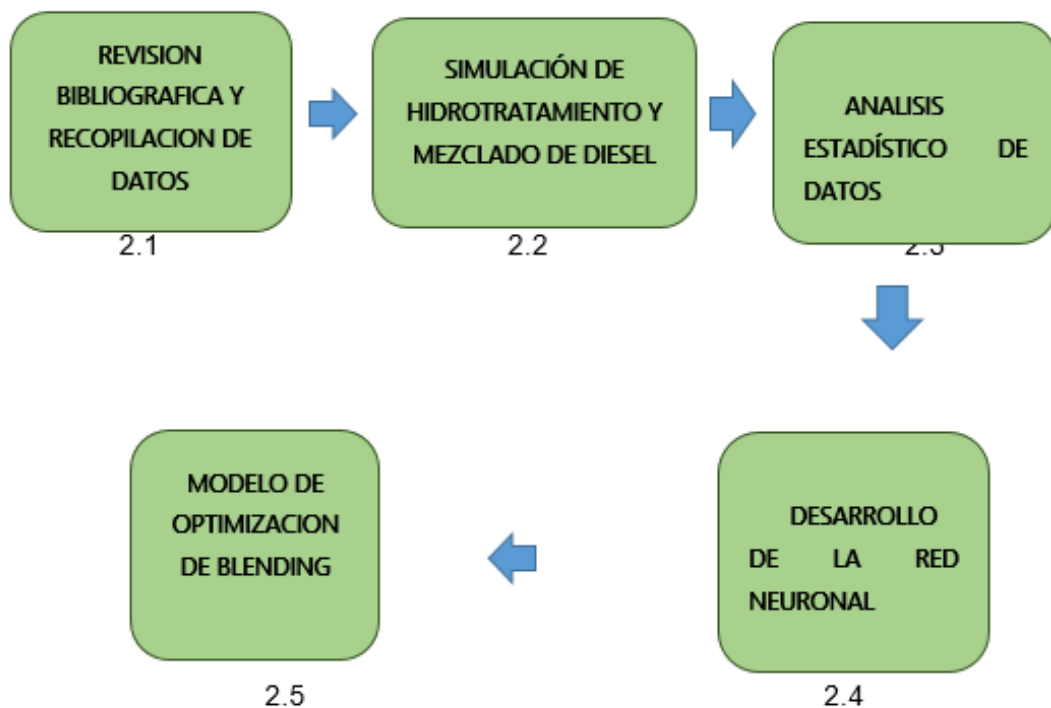
Este trabajo busca reflejar un esquema de preparación de diésel desde su punto inicial en el área de refinación, el punto de reducción de compuestos azufrados

(HDT) hasta que satisfaga las necesidades del producto en el área de blending, buscando el análisis del proceso para ser más costo efectivo para la organización optimizando la producción de diésel en el departamento de materias primas.

2. METODOLOGÍA

La siguiente figura ilustra la estructura metodológica seguida en el presente trabajo de aplicación.

Figura 6. Esquema de la metodología



2.1. REVISIÓN BIBLIOGRÁFICA Y RECOPIACIÓN DE DATOS

Al inicio, durante y al final de este proyecto de aplicación a la industria, se realizó la recopilación de datos durante los meses de enero a junio de 2016 y consulta bibliográfica para darle adecuado desarrollo al tratamiento estadístico de los datos, construcción de una simulación que reprodujera resultados en estado estacionario

similares al proceso real, además de la aplicación de las redes neuronales artificiales RNA en la predicción del proceso de hidrotratamiento y el mezclado de diésel para llegar a la optimización deseada.

2.2. SIMULACIÓN DE HIDROTRATAMIENTO Y MEZCLADO DE DIÉSEL

La simulación de la producción de diésel consideró la mezcla de crudos en refinación, la torre de destilación atmosférica, la unidad de hidrotratamiento y la preparación de diésel como producto final (B₂E). Para esto, los assays de los crudos utilizados en destilación fueron especificados en HYSYS, junto con el modelo termodinámico Grayson-Streed, según lo recomendado en la Figura 7. Con respecto al hidrotratamiento fue necesario el uso del modelo termodinámico HCRSRK especializado para la unidad HDT [22]. Este modelo toma los pseudocomponentes y los transforma en compuestos definidos que normalmente son sometidos al hidrotratamiento. La tabla 3 muestra las recomendaciones establecidas para la escogencia de los diferentes modelos termodinámicos de acuerdo al proceso a evaluar.

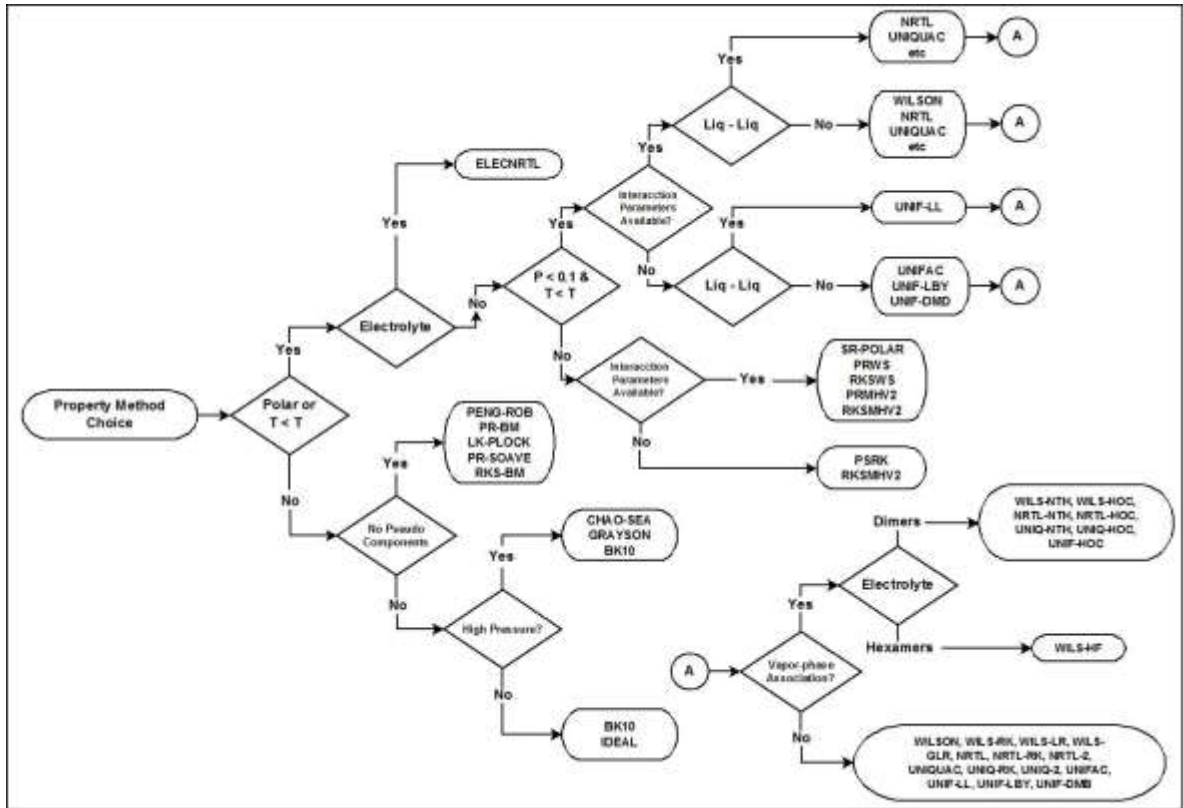
Para el sistema de *Blending* o mezclado se empleó el paquete termodinámico de Peng Robinson, el cual resulta el más conveniente según el árbol de decisiones expuesto por Aspen (Figura 7). La validación de la simulación fue realizada por medio de la tabla ANOVA entre los datos históricos de proceso y los resultados de las simulaciones. De otro lado, un análisis de sensibilidad fue desarrollado con la herramienta “cases studies” de Aspen Hysys, donde se selecciona cada variable con sus respectivos rangos de variabilidad para determinar los respectivos perfiles y tendencias.

Tabla 3. Recomendaciones para la escogencia del modelo termodinámico

Tipo de proceso	Paquete Termodinámico recomendado
Deshidratación de TEG	PR
Acuoso ácido	Sour PR
Procesamiento de gas criogénico	PR, PRSV
Separación de aire	PR, PRSV
Torres atmosféricas de crudo	PR y sus variantes, Grayson Streed (GS)
Torres a vacío	PR y sus variantes, GS, Braun K10, Esso
Torres de etileno	Lee Kesler Plocker
Sistemas con alto contenido de H₂	PR, Zudkevitch-Jofee (ZJ), GS
Reservorios	PR y sus variantes
Sistemas de vapor	ASME Steam, Chao Seader, GS
Inhibición de hidratos	PR
Productos químicos	Modelos de actividad, PRSV
Alquilación de HF	PRSV, NRTL
Hidrocarburos-agua (alta solubilidad del agua en HC)	Kabadi Danner
Separación de hidrocarburos	PR, SRK
Aromáticos	Wilson, NRTL, UNIQUAC
Producción de éter (MTBE, ETBE, teramil metil eter TAME)	Wilson, NRTL, UNIQUAC
Plantas de etilbenceno / estireno	PR, SRK O Wilson, NRTL, UNIQUAC (según la tecnología de producción)
Producción de ácido tereftálico	Wilson, NRTL, UNIQUAC
Craqueo catalítico, Hidrotratamiento	HCRSRK

Fuente: ASPEN-TECH, Honeywell

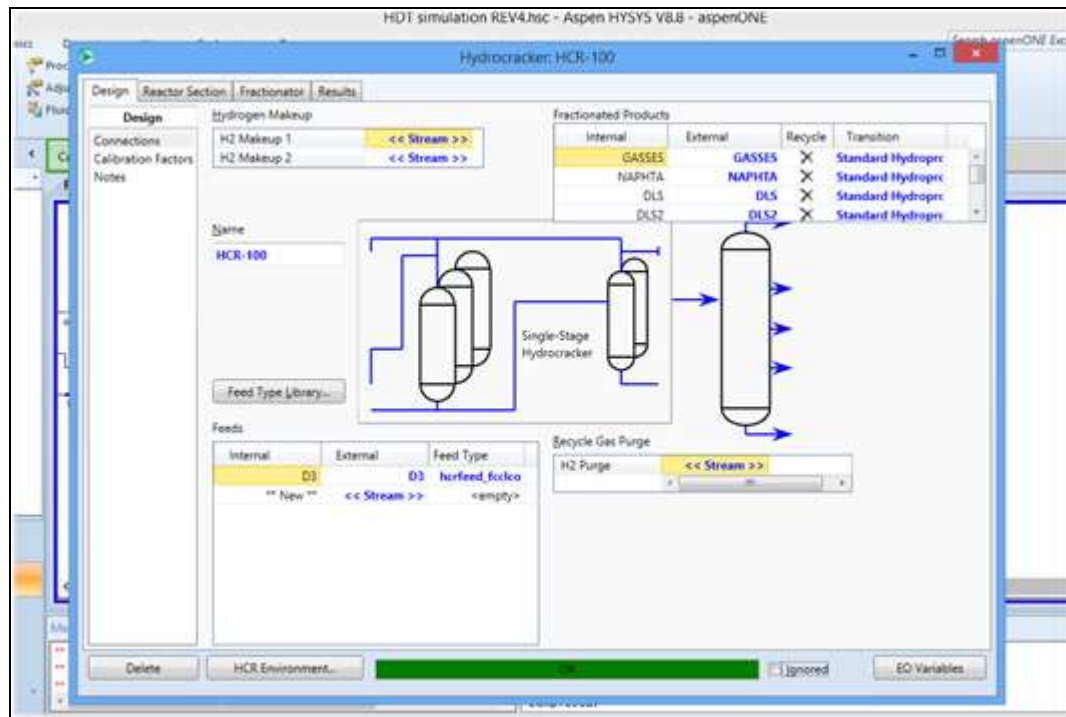
Figura 7. Árbol de decisión para la escogencia de modelo termodinámico.



Fuente: Hand Book of processes simulation. Aspen Tech

La simulación consideró la unidad conformada por 2 reactores que diferentes catalizadores con características especiales para cumplir el proceso requerido, tal como se aprecia en la figura 8. Los datos utilizados para las reacciones fueron tomados de los manuales de AXXEN Ecopetrol, el cual es información confidencial de la compañía y la organización. El autor de este documento se reserva los derechos de publicación.

Figura 8. Diagrama de esquema de la simulación de hidrotratamiento de diesel en GRB



2.3. ANÁLISIS ESTADÍSTICO DE DATOS

Los datos históricos de planta utilizados corresponden a registros minuto a minuto del proceso de hidrotratamiento de la unidad U-4700 de la refinería de Barrancabermeja durante los meses de enero a Junio del presente año. Estos datos conforman una matriz de 23400 x 12 datos, cuyas columnas corresponden a: El flujo de ACPM con alto contenido de azufre y algunas de sus propiedades como el punto inicial de ebullición, punto final de ebullición, grado API, y el contenido de azufre; también se consideraron ciertas condiciones de operación en la zona de reacción como presión de operación, temperatura de entrada y cambio de temperatura en la zona de reacción, la relación hidrógeno/hidrocarburo y el flujo de hidrógeno alimentado, además del flujo de diésel hidrotratado y su contenido de azufre.

Considerando la anterior matriz, diferentes análisis estadísticos univariados y bivariados fueron aplicados a los datos históricos para definir los estadísticos valores mínimos, máximos y promedios, desviaciones estándar y coeficientes de correlación; a su vez, se realizaron las gráficas de dispersión con las cuales se observó el comportamiento de las variables y sus interacciones entre sí. Por otra parte, mediante el análisis estadístico de caja y bigotes (*box-plot*) se tomaron como valores atípicos aquellos que se encontraban fuera del rango. Las condiciones de operación atípicas fueron analizadas para determinar la eliminación de los puntos respectivos de la base de datos [23] [24]

2.4. DESARROLLO DE LA RED NEURONAL

El entrenamiento y la validación de las RNA fue efectuado utilizando la herramienta *Toolbox nntool* de Matlab R2015a (*The MathWorks, inc.*), a través de las siguientes actividades.

2.4.1. Diseño y arquitectura de las redes neuronales. Las RNA probadas fueron definidas como de tipo feedforward Backpropagation con funciones de activación logsig; la arquitectura de red consideró una capa oculta de la forma (X:N:Y), donde X, N y Y hacen referencia al número de neuronas en la capa de entrada, capa oculta y capa de salida, respectivamente. Estas arquitecturas para las RNA fueron propuestas por Arce & Paz [13] y Lukec & Sertic [12] en sus análisis relacionados con el proceso de hidrotreamiento. El desempeño de la arquitectura de la red fue analizado cambiando diferentes funciones de activación en la capa oculta y en la capa de salida, utilizando las funciones logsig-logsig y logsig-purelin. Asimismo, el número de neuronas fue modificado hasta encontrar el mejor modelo de red, siguiendo la restricción para el número de neuronas en la capa oculta (i.e. el número de neuronas en las capas ocultas no debe superar al doble del número de variables de entrada) [25] [26].

2.4.2. Entrenamiento de la red neuronal. Para la función de entrenamiento y adaptación, se utilizó la función de Matlab denominada `trainlm`, considerando el 70% de los datos. El algoritmo de esta función actualiza los pesos y las ganancias de acuerdo a la optimización de Levenberg-Marquardt; el desempeño de este algoritmo de entrenamiento es superior para las redes tipo Backpropagation [8].

2.4.3. Validación de las redes neuronales. Las RNA entrenadas fueron validadas utilizando el 30% de los datos históricos restantes. Los parámetros R^2 y el error cuadrático medio (ECM) también conocido del idioma inglés como Mean Squared Error (MSE) de entrenamiento y de validación fueron determinados para establecer la mejor RNA para el proceso de hidrotratamiento.

2.5. MODELO DE OPTIMIZACIÓN DE BLENDING

El modelo de optimización de las mezclas de diésel fue propuesto considerando las propiedades más significativas según los parámetros de calidad establecidos en la norma técnica colombiana NTC 1438. Estas propiedades fueron destilación, azufre, viscosidad cinemática y punto de inflamación. El modelo matemático consideró la aplicación de reglas de mezclas para las respectivas propiedades. El modelo matemático fue configurado en EXCEL y resuelto utilizando la herramienta Solver. Los resultados de este modelo de optimización fueron contrastados con los resultados obtenidos en HYSYS y con los datos históricos de preparación del diésel comercial B₂E. La función objetivo fue el margen de ganancia por la preparación de diésel teniendo en cuenta el precio de cada componente y la proporción a utilizar en las diferentes mezclas.

3. SIMULACIÓN EN HYSYS DEL SISTEMA HDT-BLENDING

Las características de los flujos de acpm disponibles en la sección de mezcla de productos finales influyen sobre los requerimientos de acpm de la unidad HDT; la severidad de operación de la unidad se incrementa para cumplir con porcentajes bajos de azufre del orden de 20 ppm o menos. En diferentes ocasiones, la severidad especificada en la unidad HDT puede ser exagerada para los requerimientos de azufre del correspondiente flujo. En este capítulo se analizan dos simulaciones, una para el sistema HDT y otra para el sistema de blending tendientes a definir condiciones operativas en HDT que satisfagan los requerimientos de azufre para el diésel B₂E comercial.

3.1. SIMULACIÓN UNIDAD HDT

Los assays de los diferentes crudos de carga al área de refinación de la GRB fueron definidos en la opción “Petroleum assays” de HYSYS. Diferentes flujos de masa fueron asociados a los assays definidos para crear las mezclas establecidas por la coordinación de planeación para el área de blending de crudos. Estas mezclas fueron alimentadas a una torre de destilación representativa del área de refinación de crudos de la Unidad 250 (U-250), para extraer las propiedades del corte de acpm; la Tabla 4 presenta las características operativas de la torre codificada en estado estacionario. El corte de acpm corresponde a la corriente de carga a la unidad HDT (Figura 9). La unidad HDT fue configurada considerando los intercambiadores de calor y los reactores según su distribución en planta (Figura 10). Los reactores de la unidad fueron especificados con diferente catalizador y con sus características particulares según las hojas de especificaciones respectivas. Los parámetros utilizados para las reacciones fueron

tomados de los manuales de AXXEN de la unidad –energías de activación, modelo cinético, velocidad espacial y constantes de reacción–.

Tabla 4. Especificaciones de operación de la Unidad 250

Parámetros		EQUIPO			
		Torre atmosférica	Torre despojadora de Jet	Torre despojadora de acpm	Torre despojadora de gasóleo
N° de platos		32	4	4	4
Vapor de despojo	Presión (psig)	50	50	50	50
	Flujo (Lb/h)	5000	1000	0-500	1000-1500
	Temp. (F)	720	720	720	720
<i>Pumparound</i> (reflujo en Bpd)	Cima	10000-15000	No aplica	No aplica	No aplica
	Medio	10000-15000	No aplica	No aplica	No aplica
	Inferior	9000-15000	No aplica	No aplica	No aplica
Carga	Flujo (B)	42000	No aplica	No aplica	No aplica

Los resultados de las simulaciones de la U-250 con las diferentes mezclas de crudo reportan que los flujos de salida de acpm con una cantidad elevada de azufre, lo cual es característico de la operación de la unidad U-250; según datos históricos, el acpm efluente de las unidades 2000 y 2100 reporta fluctuaciones leves en los contenidos de azufre, la mezcla de todas las corrientes es caracterizada y analizada para la carga general a la Unidad de Hidrotratamiento (Figura 11). Las variaciones de azufre en el acpm efluente de la U-250 son causadas por la cantidad de crudo LCT cargado; según la Figura 12, a mayor cantidad de crudo LCT menor porcentaje de azufre en el acpm resultante de las unidades de refinación. Los resultados del contenido de azufre a la salida de las unidades de destilación se ven reflejados en la mezcla de acpm que es almacenado en el tanque de carga a la unidad de hidrotratamiento.

Figura 10. Intercambiadores y reactores codificados en HYSYS para la unidad HDT.

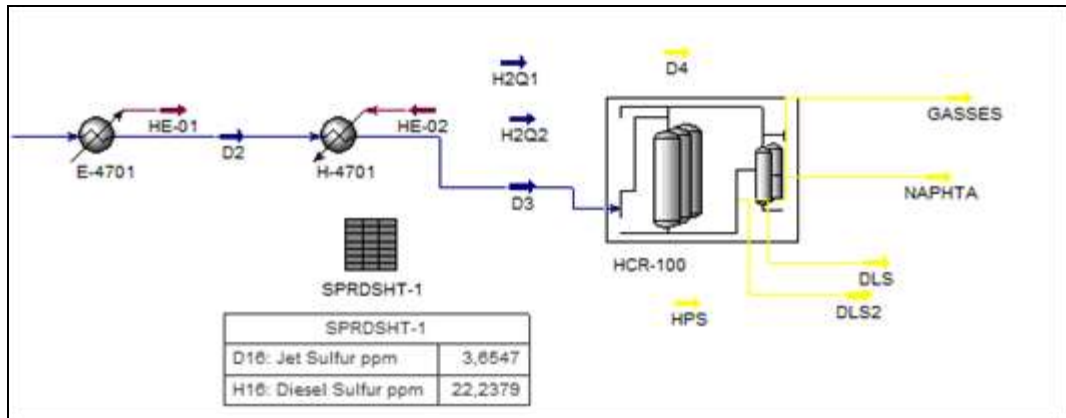


Figura 11. Tendencia histórica de contenido de azufre total en la carga a HDT


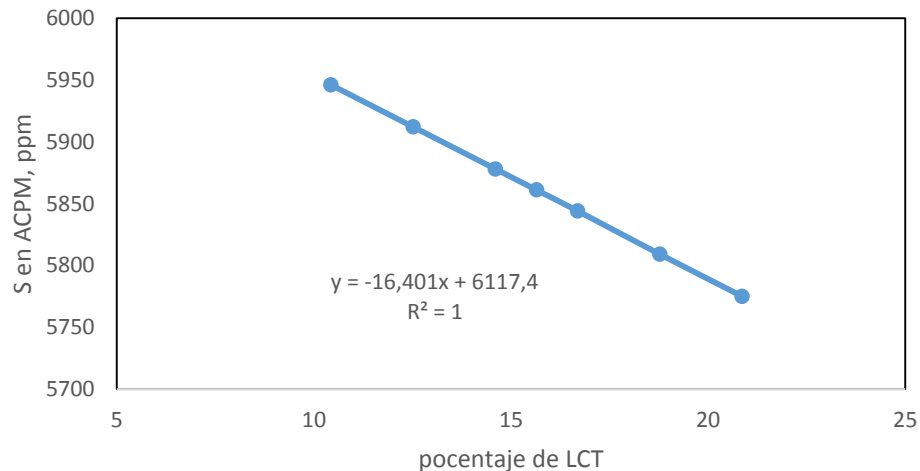


Figura 12. Cambios en la composición de azufre en el acpm cargado en HDT por variación del porcentaje de crudo LCT destilado en la U-250, según simulaciones.



De otro lado, los resultados de las simulaciones de la unidad HDT fueron comparados con datos de laboratorio. Los promedios de las propiedades contenido de azufre y temperatura al 95% de evaporado (T95 – propiedad importante en los diésel comerciales debido a la capacidad de compresibilidad del motor con fracciones pesadas inferiores a 370°C; compuestos con punto de ebullición superiores necesitan mayor tiempo de residencia y temperaturas superiores para evitar la generación de carbón particulado en los gases de combustión) [27] fueron comparados para la ventana de operación de la unidad HDT entre los meses de enero y junio del año 2016. La Tabla 5 presenta la comparación de los promedios obtenidos de los datos históricos y de las simulaciones, de acuerdo a los intervalos de confianza al 95%; la Tabla 6 reporta los resultados del análisis ANOVA de la comparación de muestras independientes realizada para validar los datos de la simulación para el contenido de azufre. Donde la hipótesis nula en la ANOVA corresponde a que la media y la varianza de los datos obtenidos por simulación coincide con las reportadas en los datos históricos. Según la tabla ANOVA los datos reportados por la simulación reproducen los datos históricos para la operación de la unidad HDT, puesto que el

valor p de probabilidad es mayor a 0,05 se acepta la hipótesis nula –la media y la desviación estándar de los dos conjuntos de datos son iguales–.

Tabla 5. Promedios de contenido de azufre (ppm) en el acpm hidrotratado en la ventana de operación.

Histórico de azufre (ppm) en el acpm hidrotratado	Simulación S (ppm) acpm hidrotratado.	Límite Inferior histórico	Limite Superior histórico
26,0± 5.3	28,4±7,7	20,7	31,3

Tabla 6. Tabla ANOVA para la validación del contenido de azufre obtenido por simulación.

ANÁLISIS DE VARIANZA					
<i>Origen de las variaciones</i>	<i>Suma de cuadrados</i>	<i>Grados de libertad</i>	<i>Promedio de los cuadrados</i>	<i>F</i>	<i>Probabilidad</i>
Entre grupos	51.1042	1	51.155	0.4049	0,295662
Dentro de los grupos	21.1254	12	36.11		
Total	72.22	13			

Asimismo, la Tabla 7 presenta los promedios obtenidos de los datos históricos y de las simulaciones y los respectivos límites al 95% confianza para las temperaturas de evaporado del acpm hidrotratado; la Tabla 8 reporta el resultado de la ANOVA realizada para validar los datos de la simulación para la destilación T95% del acpm hidrotratado. La hipótesis nula en la ANOVA corresponde a que la media y la varianza de los datos obtenidos por simulación y por los datos históricos son iguales. Según la tabla ANOVA los datos reportados por la simulación reproducen los datos históricos para la T95% del acpm hidrotratado; la diferencia entre medias corresponde a -0,64 +/- 1,51 °F, con lo cual no hay diferencia significativa entre las medias de las dos muestras de datos (95% confianza).

Tabla 7. Resultados destilación según datos históricos y simulaciones.

Porcentaje en volumen de recobrado, %	ACPM HDT real	ACPM HDT real	Intervalo de confianza	
	Histórico en °C	Simulado en °C	Límite Inferior en °C	Límite Superior en °C
0,	210,50±4,92	215,05±2,34	205,5	215,4
10	255,00±5,09	249,07±1,39	249,9	260,0
50	305,50±0,77	299,45±1.97	304,7	306,2
90	369,50±5,15	367,28±1.87	364,3	374,6
95	382,80±3,39	379,53±0.79	379,4	394,1
100	389,50±5,04	390,29±1.21	384,4	394,5

Tabla 8. Tabla ANOVA para la verificación de los datos de simulación para la destilación T95% del acpm hidrotratado.

ANÁLISIS DE VARIANZA					
Origen de las variaciones	Suma de cuadrados	Grados de libertad	Promedio de los cuadrados	F	Probabilidad
Entre grupos	0,05901	1	0,05901	0,00952	0,9242
Dentro de los grupos	61,9562	10	6,19562		
Total	62,0152	11			

3.1.1. Análisis de sensibilidad para la composición del crudo. La simulación de la unidad HDT reporta un incremento en el acpm hidrotratado a medida que se incrementa la composición de crudos nafténicos, los cuales presentan una mayor proporción de tiofenos –aromáticos azufrados de dos, tres y cuatro anillos–. La presencia de crudos con compuestos azufrados como tiofenos y dibenzitiofenos disminuye la eficiencia del catalizador de HDT en la remoción de azufre, por lo cual, un crudo nafténico como el LCT presenta una mayor resistencia al proceso HDT [28]; aunque una mayor proporción de crudo LCT en la carga a destilación genera un flujo de acpm con menor cantidad de azufre (Figura 12), el producto hidrotratado en HDT reporta un aumento en la cantidad de azufre con el aumento de este crudo (Figura 13).

Respecto a la destilación, las simulaciones reportan que el acpm hidrotratado presenta valores de T95% constantes hasta una cantidad de ca. 19% de crudo LCT; porcentajes superiores de LCT en la carga a destilación tienden a disminuir los valores de T95% en el acpm efluente de HDT (Figura 14). Esta tendencia puede ser explicada debido al retiro en la carga del crudo pesado (Nare), el cual refleja una destilación mayor y el corte del punto final más elevado que el crudo LCT. Según lo anterior, un aumento por encima de 19% de crudo LCT genera un flujo de acpm hidrotratado con destilación más baja, el cual requerirá menor dosificación de corrientes de baja destilación para ajustar el requerimiento de diésel comercial.

Figura 13. Cambios en el contenido de azufre hidrotratado vs cambios en la carga de crudo.


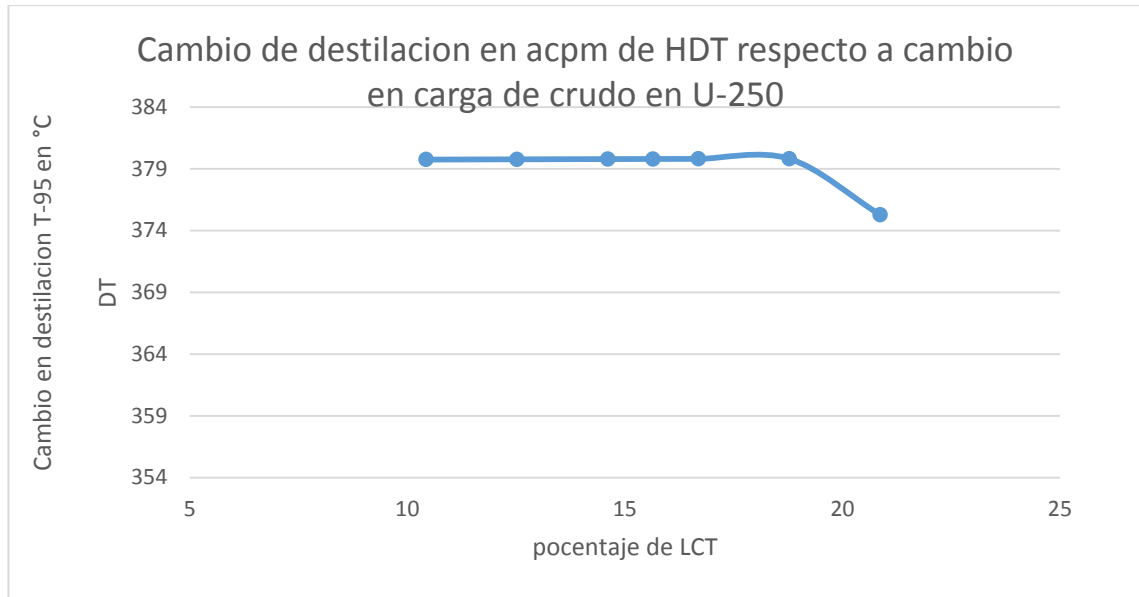


Figura 14. Cambio en los valores de T95 del acpm hidrotratado según carga de crudo LCT a unidades de destilación.



De otro lado, según las simulaciones, un incremento en la composición de crudos ácidos (crudo Nare) a las unidades de refinación aumenta la temperatura en los lechos de reacción e incrementar la composición de azufre en acpm hidrotratado. La Figura 15 presenta la variación de las temperaturas de los lechos y el contenido de azufre del acpm hidrotratado con un aumento en la composición de crudo ácido. Según la destilación, el crudo Nare presenta un potencial de generación de acpm de ca. 12% por barril cargado (Figura 16). De lo anterior se puede establecer, por ejemplo, que en la unidad de destilación al cargar 12 Kilo barriles por día de operación (KBPDO) de crudo Nare la conversión hacia acpm será de 1440 Bls de acpm. Con lo anterior, la contribución del crudo Nare al acpm efluente de destilación será solo de ca. 3.2%, presentando una baja incidencia en las propiedades resultantes para este efluente (Figuras 16 y 17).

Figura 15. Variación en la temperatura de los reactores y en el contenido de azufre del acpm hidrotratado según la dosificación de crudo ácido.




Figura 16. Conversión de crudo Nare y LCT en productos destilados.


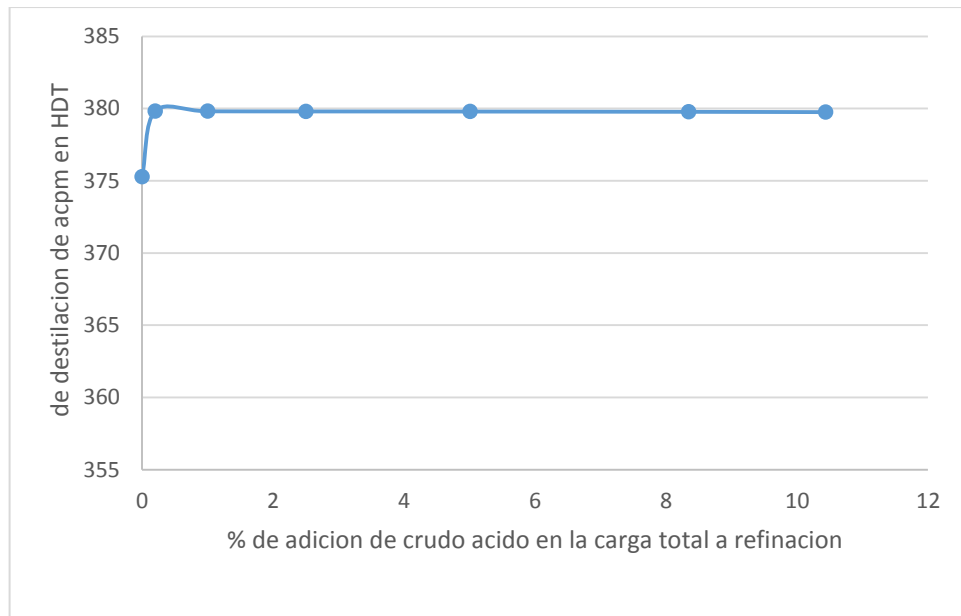
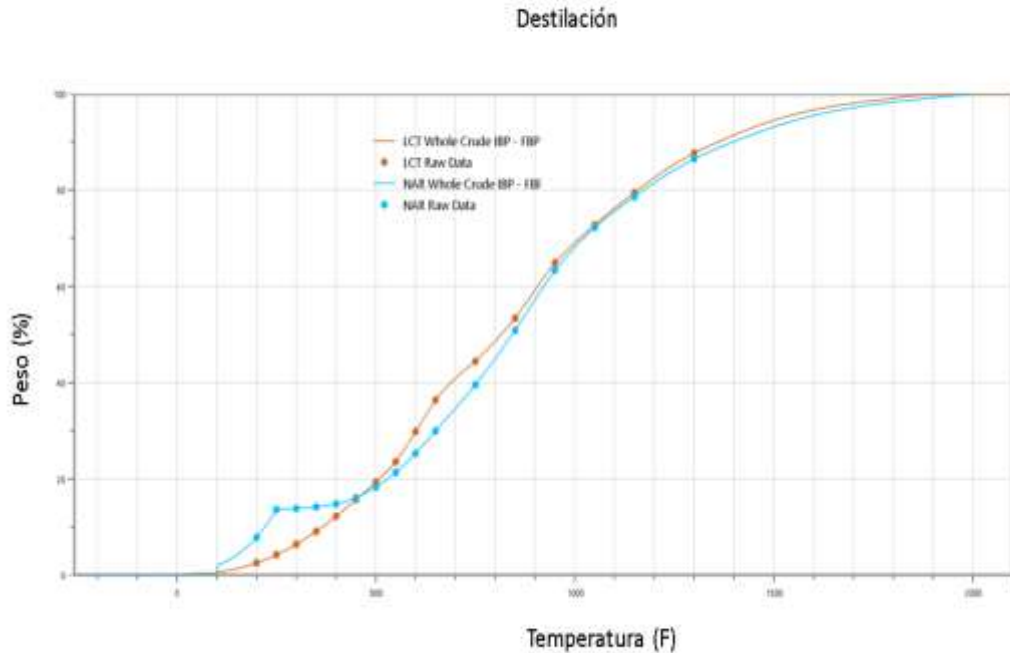


Figura 17. Cambio en la destilación del acpm (T95%) de acuerdo al porcentaje de crudo ácido cargado en destilación.



El aporte menor del crudo Nare en el acpm de destilación, muestra su leve incidencia en las propiedades del diésel preparado; Por otra parte, de acuerdo a la figura 16, este crudo presenta mayor aporte como gasóleo, siendo este un subproducto que sirve de materia prima para la carga a las unidades de craqueo catalítico y convertirse en nafta de mayor octanaje. La comparación de las curvas de destilación entre los crudos LCT y Nare (Figura 18) conduce a la afirmación de que el crudo LCT produce una mayor cantidad de acpm que el destilado a partir del crudo Nare.

Figura 18. Curvas TBP de crudo Nare y LCT



3.2. SIMULACIÓN SECCIÓN DE MEZCLA (BLENDING)

La simulación de la entrada de las corrientes a los cabezales de mezcla del sistema de blending de diésel fue establecida de acuerdo a las especificaciones de diseño consignadas en el capítulo 1. Las corrientes utilizadas en las simulaciones fueron: acpm importado, nafta pesada (*Virginoil*), acpm proveniente de UNIBON, biodiesel y las corrientes de acpm hidrotratado y de jet hidrotratado de HDT. Estas corrientes fueron especificadas según los datos históricos para la ventana de operación de enero a junio de 2016. En la Tabla 9 se muestra el análisis realizado a la comparación de los datos de destilación de la simulación de blending y los valores históricos de laboratorio respecto a la destilación. Esta tabla contiene el resumen estadístico para las dos muestras de datos. De particular

interés son el sesgo y la curtosis que pueden usarse para comparar si las muestras provienen de distribuciones normales. Valores de estos estadísticos fuera del rango de -2 a +2 indican desviaciones significativas de la normalidad [24] [29]; los valores de sesgo y curtosis se encuentran dentro del rango esperado.

Tabla 9. Comparación datos históricos con resultados de simulación para el blending de acpm.

	T95% en ° C Simulación	T95% en ° C histórico
Promedio	369,7	370,2
Desviación Estándar	0,24	1,94
Coefficiente de Variación	0,06%	0,52%
Mínimo	369,4	367,9
Máximo	370,1	373,8
Rango	0,7	5,9
Sesgo Estandarizado	0,18	0,99
Curtosis Estandarizada	-0,13	0,61

De otro lado, la Tabla 10 presenta los resultados de la tabla ANOVA aplicada para verificar la igualdad entre los resultados de las simulaciones y los datos históricos. La hipótesis nula corresponde a la igualdad entre medias y varianzas. Según la Tabla 10, la hipótesis nula es aceptada. La diferencia de medias corresponde a - 0.51 +/- 1.61°C, lo cual valida adicionalmente la hipótesis nula al 95% confianza.

Tabla 10. Análisis de varianza de destilación en blending.

ANÁLISIS DE VARIANZA					
<i>Origen de las variaciones</i>	<i>Suma de cuadrados</i>	<i>Grados de libertad</i>	<i>Promedio de los cuadrados</i>	<i>F</i>	<i>Probabilidad</i>
Entre grupos	0,24083333	1	0,240833333	0,1119	0,7448
Dentro de los grupos	21,5216667	10	2,152166667		
Total	21,7625	11			

Asimismo, en la Tabla 11 se muestra la comparación de los porcentajes de destilación entre los valores reales y simulados en el diésel real con un intervalo de confianza del 95%. En la tabla 12 se muestra la comparación de las muestras

de azufre en el diésel del blending real vs simulado, reflejándose que no se rechaza la hipótesis nula, es decir se acepta, donde la desviación y la varianza de los componentes es similar, gran parte de esto se debe a que las muestras tienden a los resultados similares con un promedio entre 28.8 y 32 ppm de azufre. Cabe resaltar que la desviación estándar del proceso simulado es menor que el proceso real, gran parte de esto se debe a que la simulación de la mezcla del diésel fue creada en Hysys implementando el sistema de optimización, comparado contra el “solver” utilizado actualmente en la refinería.

Tabla 11. Tabla comparativa de resultados de blending

Porcentaje en volumen de recobrado, %	Destilación Real Blending	Destilación Simulación Blending	Límite Inferior	Límite Superior
0,00	180,85	187,61	168,40	193,30
5	216,53	217,77	205,54	227,51
10	233,13	228,10	222,37	243,88
50	296,20	296,24	294,21	298,19
90	358,85	359,63	357,46	360,24
95	370,98	369,7	368,98	372,97
100	381,28	384,0	379,00	383,55

Tabla 12. Comparación de muestras entre azufre real vs simulado en blending

	Azufre Blending Simulado en ppm	Azufre Blending Real en ppm
Desviación Estándar	2,69	3,95
Varianza	7,25	15,60
GI	6	6

3.3. ACOPLA PROCESO HDT Y SECCIÓN DE BLENDING

En una mezcla, el contenido de azufre resultante corresponde a la sumatoria de la fracción másica de cada flujo por su contenido de azufre; de este modo hay una

proporcionalidad directa entre el azufre en la corriente de salida HDT y el contenido de azufre del diésel comercial B₂E. Los datos históricos de mezclado de los diferentes flujos de preparación de B₂E fueron utilizados para una regresión entre el azufre del producto comercial y el azufre del flujo de acpm hidrotratado. En la Tabla 13 se muestra que la regresión explica un 99,99% de la varianza en el contenido de azufre resultante del blending, confirmando la mezcla lineal de esta propiedad. La ecuación de regresión cumple como modelo estadístico para definir el comportamiento de la variable dependiente a partir de la variable independiente. Cabe resaltar que el intercepto de la ecuación de regresión significa el máximo contenido de azufre que presenta el diésel B₂E preparado, con lo cual, el proceso HDT aportaría ca. 40% de su valor para cumplir la especificación de calidad comercial; *i.e.* el intercepto significa contenido inicial de azufre al mezclar todos los componentes excluyendo el diésel de hidrotratado.

Tabla 13. Análisis de varianza de la dependencia de la preparación de diésel

	<i>Grados de libertad</i>	<i>Suma de cuadrados</i>	<i>Promedio de los cuadrados</i>	<i>F</i>	<i>Valor crítico de F</i>
Regresión	1	43,4823	43,4823	135095,715	2,82921E-12
Residuos	5	0,00160	0,0003		
Total	6	43,4839			

<i>Estadísticas de la regresión</i>	
Coeficiente de correlación múltiple	0,9999
Coeficiente de determinación R²	0,9999
R² ajustado	0,9999
Error típico	0,0179
Observaciones	7

	<i>Coeficientes</i>	<i>Error típico</i>	<i>Estadístico t</i>	<i>Probabilidad</i>
Intercepción	20,050	0,040	495,8	6,3327E-13
Variable X1	0,58627787	0,0016	367,5	2,8292E-12

La cantidad de azufre requerida a la salida de la unidad de hidrotratamiento fue estimada, considerando los requerimientos de calidad especificados por la normatividad legal. Los resultados de contenido de azufre en el efluente de HDT reportan que es posible utilizar hasta un 55% de acpm hidrotratado con hasta 54 ppm en la mezcla total para generar un diésel comercial con contenidos de azufre de ca. 35 ppm. Lo anterior impacta en la economía y en el margen de ganancia de la refinación al poder extender el tiempo de la corrida de la unidad de hidrotratamiento, esto permitirá disminuir la severidad de operación de la planta. Adicionalmente y de acuerdo a la figura 3, es posible tener un potencial económico en la organización hasta 2 dólares por barril de diésel preparado por una adecuada proporción de azufre en el producto final.

Complementariamente, los flujos de cada componente y los volúmenes obtenidos al final de la mezcla para la preparación de diésel B₂E fueron evaluados según dos escenarios. En el primer escenario, el B₂E es obtenido a partir de las corrientes básicas de acpm Hidrotratado, acpm importado y jet hidrotratado. En la Tabla 14 aparecen los resultados de las condiciones de reactor para los cuales se logró esta mezcla.

Tabla 14. Resultados operativos en la zona de reacción para mezclas de Blending.

Operación de HDT de acuerdo a los resultados de la simulación											
Zona de reacción		Reactor 1						Reactor 2			
		Lecho 1		Lecho 2		Lecho 3		Lecho 1		Lecho 2	
hidrógeno de reposición	Presión zona de reacción	T. Salida	T. promedio	T. Salida	T. promedio	T. Salida	T. promedio	T. Salida	T. promedio	T. Salida	T. promedio
MMSC FD	Kpa	°C	°C	°C	°C	°C	°C	°C	°C	°C	°C
15,94	4725	364,1	361,79	354,04	353,03	353,6	353,07	351,3	351,21	351,12	351,08

En esta etapa se analizaron las especificaciones de calidad de los diferentes componentes de acuerdo a los resultados de la simulación apreciándose que los ajustes dentro del área de reacción permiten tener un acpm hidrotratado efluente en valores inclusive de 55 ppm de azufre y destilación en 378°C al 95% de recobrado. De acuerdo a las mezclas realizadas se obtiene un diésel producto con 369,7°C al 95% de recobrado y con contenido de azufre de 37 ppm. La Tabla 15 muestra las características de los componentes y el producto final resultante del primer escenario.

Tabla 15. Tabla de resultados de preparación de diésel con componentes básicos.

Preparación de diésel B ₂ E con los componentes básicos				
Nombre	Jet Hidrotratado	Acpm Hidrotratado	Acpm Importado	Diésel B ₂ E
Flujo Molar [kgmol/h]	237,606	1312,450	984,966	2227,946
Flujo Másico[kg/h]	32345,492	271567,900	209297,304	466106,08
Flujo Volumétrico [Bls/d]	5668	47100	35500	79100
Azufre ppm	5,32	54,77	11,7	36,81
Destilación al 95% (° C)	213,2	378,1	353,5	369,7
Viscosidad cinemática (Cst)	1,62	4,98	4,2	4,759
Índice de cetano	41,92	47,59	46,81	46,61

En el segundo escenario, las condiciones operativas de la unidad HDT fueron fijadas, mientras la dosificación de corrientes adicionales dentro del rango de preparación fue habilitada para conseguir las propiedades comerciales del diésel producto. El flujo de acpm cargado a la unidad fue de 54000 Bls/día, de los cuales 7 kbls de jet hidrotratado y 47000 Bls de acpm hidrotratado fueron producidos. En este proceso las condiciones operativas en el área de reacción se presentan a continuación en la Tabla 16.

Tabla 16. Análisis de la operación de HDT en la simulación con la inclusión de nuevo componente de preparación.

Operación de HDT de acuerdo a los resultados de la simulación											
Zona de reacción		Reactor 1						Reactor 2			
		Lecho 1		Lecho 2		Lecho 3		Lecho 1		Lecho 2	
Flujo de hidrógeno de reposición	Presión de operación en la zona de reacción	T. Salida	T. promedio	T. Salida	T. promedio	T. Salida	T. promedio	T. Salida	T. promedio	T. Salida	T. promedio
MMSCFD	Kpa	°C	°C	°C	°C	°C	°C	°C	°C	°C	°C
16,1	4725	364,28	361,91	354,08	353,05	353,63	353,09	351,29	351,19	351,10	351,07

Los resultados de la simulación con este escenario muestran que con las condiciones normales de la preparación, es posible aprovechar la operación de la unidad para generar mayores ganancias al margen con el aprovechamiento de nuevas corrientes. Con lo anterior, el escenario 2 habilita la inclusión del flujo de acpm de Unibón, el cual presenta características de azufre de hasta 2600 ppm y 408°C para el 95% de recobrado. La preparación admite un flujo de 3000 Bls/día de acpm de Unibón en preparaciones de 79000 Bls/día de diésel. Adicionalmente si las condiciones operativas lo requieren, por estrategias de planeación de la producción para manejo de inventarios, posicionamiento de producto en un nuevo mercado e inclusive por oportunidad de elaboración de un diésel con otras especificaciones para clientes adicionales, se aprecia la posibilidad de preparación de 8000 Bls de un acpm excedente con 7.43 ppm de azufre y 374 ° C en T-95 el cual brinda las oportunidades para ser utilizado incluso como componente de nuevas preparaciones ó en la estrategia de preparación de diésel marino como se puede visualizar en la Tabla 17.

Tabla 17. Resultados con la inclusión de acpm de UNIBON

Preparación de diésel B ₂ E con los componentes básicos incluyendo ACPM UNIBON						
Nombre	Jet Hidrotratado	Acpm Hidrotratado	ACEM	Diésel B ₂ E	ACPM UNIBON	ACPM Excedente
Flujo Molar [kgmol/h]	239,2	1308	985	2233	73,89	307,077172
Flujo Másico[kg/h]	32550,47	271193,43	209297,3045	468438,85	18050	47104,6072
Flujo Volumétrico [Bl/d]	5700	47100	35500	79080	3000	8000
Azufre ppm	6,25	28,9	11,7	36,81	2662	7,43
Destilación al 95% (° C)	213,15	378	353,5	369,5	408,7241219	374,4
Viscosidad cinemática (Cst)	1,62	5,32	4,2	4,9	3,3	2,15
Índice de cetano	41,92	47,59	46,81	47,07	49	42,52
Punto de inflamación	42,98	96,09	100,8	95,85	118,6	57.5

4. DESARROLLO Y VALIDACIÓN DE UNA RED NEURONAL

4.1. SELECCIÓN DE DATOS HISTÓRICOS DE ESTADO ESTACIONARIO

La unidad de hidrotreatmento de diésel de la Gerencia Refinería Barrancabermeja (GRB) cuenta con monitoreo operacional por medio de la herramienta denominada PI. El monitoreo operativo de la planta también se soporta en el seguimiento de las características de los productos, componentes e insumos utilizados en el proceso. Los datos históricos fueron recolectados considerando la ventana operacional entre los meses de diciembre de 2015 y mayo del 2016; los datos corresponden a reportes de las variables cada minuto, con lo cual una cantidad de 23000 valores fueron utilizados para cada variable. Las variables consideradas en los datos históricos fueron las temperaturas de reacción, la presión de hidrógeno, la relación carga hidrógeno, punto inicial de ebullición, punto final de ebullición, gravedad API, flujo de la carga de acpm, concentración de azufre a la entrada a la zona de reacción y la concentración de azufre en la salida de acpm tal como se describe en la Tabla 18.


Es importante aclarar que el análisis se centró en el área de reacción de hidrotreatmento de acpm, donde la corriente con alto contenido de azufre que ingresa a la unidad sufre el cambio de su composición y se extrae la mayor cantidad de azufre para generar un acpm con menos de 50 ppm, que será utilizado como componente principal en la preparación de diésel.

Tabla 18. Resumen de estadísticos para cada variable en la ventana operativa.

SIMBOL O	DESCRIPCIÓN DE LAS VARIABLE	UNIDADES	VALOR MÍNIMO	VALOR PROMEDIO	VALOR MÁXIMO	DESVIACIÓN ESTÁNDAR
HC1	Flujo de ACPM con alto contenido de azufre	$\frac{\text{bls}}{\text{min}}$	31853,660	52627,826	64941.879	5517.487
PIB	Temperatura inicial de ebullición	°F	333,500	390,025	414,900	19,966
PFB	Temperatura final de ebullición	°F	719,1	737,095	759,7	8,275
API	Densidad relativa para líquidos del petróleo	°API	28,400	29,720	30,899	0,383
S1	Concentración de azufre en HC1	ppm	3985,000	4786,103	5603,000	349,327
H	Hidrógeno alimentado en la entrada a la zona de reacción	$\frac{\text{mol}}{\text{min}}$	105,532	126,336	142,636	5,864
RR	Relación ACPM / hidrógeno	$\frac{\text{bls}}{\text{mol}}$	233,424	418.359	560.212	54,896
T1	Temperatura de entrada a la zona de reacción	°F	577,521	636,000	669,330	3,521
dT	Cambio de temperatura en la zona de reacción	°F	5,569	41,941	100,777	1,921
P	Presión de operación en la zona de reacción	psia	675,511	684,918	688,478	0,677
HC2	Flujo de ACPM hidrotratado	$\frac{\text{bls}}{\text{min}}$	26942,305	47578,168	60366,645	5473,037
S2	Concentración de azufre en HC2	ppm	5,000	26,923	50,000	10,623


En la figura 19 se observa la dispersión de flujo de acpm cargado a la unidad durante el periodo de tiempo en el cual se realizó el análisis, aunque se observan algunos valores por el orden de los 30000 Bls/día, la tendencia está enfocada en flujos superiores a los 50000 Bls/día. En el eje de las abscisas se consigna el número de datos recopilados para este diagrama de dispersión, para este estudio se utilizaron 23000 datos, mientras que en el eje de las ordenadas se encuentra distribuido el flujo en barriles/día.

Tabla 19. Diagrama de dispersión para el flujo de ACPM (HC1).



Adicionalmente, en la figura 20 se puede apreciar la dispersión de los valores para el punto final de ebullición, con valores entre los 715 ° F y 760 °F, lo cual indica la variación del acpm a tratar, con la presencia de compuestos más pesados en el mismo. En el anexo D se encuentran consignados los diagramas de dispersión de las variables adicionales que se escogieron para el diseño de la red neuronal, en el eje de las abscisas se consigna el número de datos utilizados y en el eje de las ordenadas los registros de punto final de ebullición en Fahrenheit.

Figura 19. Diagrama de dispersión para el punto final de ebullición (PFB).



4.2. RNA PARA EL ACPM HIDROTRATADO Y SU CONTENIDO DE AZUFRE

Al conocer las condiciones operativas de la unidad y el comportamiento de las diferentes variables que tienen mayor incidencia en el proceso de

hidrotratamiento, se busca predecir los valores óptimos en los cuales se debe operar la planta y que al final del proceso se obtenga un acpm con características más acordes a los requeridos por el área de blending para ser mezclado y cumplir con la capacidad de proceso en la preparación de diésel B₂E con el parámetro de azufre en un mejor rango de calidad. Los datos históricos considerados están mencionados al inicio de este capítulo.

La siguiente nomenclatura fue establecida para las diferentes funciones de activación: FA-I para las redes con la función *logsig-purelin* y FA-II para las redes con la función *logsig-logsig*. Las topologías asumidas corresponden a la forma 9:N:2, donde 9 es la cantidad de variables de entrada, N es el número de neuronas en la capa oculta que varía desde 2 a 18; y 2 las variables de salida (Anexo A, Figura 37) Los estadísticos de desempeño de las redes función de activación 1 y 2 (FA-I y FA-II) con las diferentes topologías para la predicción del flujo de ACPM hidrotratado y su contenido de azufre pueden ser analizados en las Tablas 19 y 20. Según estas tablas, la red neuronal FA-I de topología 9:18:2 presentó los mejores estadísticos tanto para el entrenamiento como para la validación. También las redes FA-II presenta su mejor desempeño en la topología 09:16:02 (Tabla 20).

Para determinar el mejor desempeño de la red neuronal se tuvo en cuenta la aplicación de los estadísticos R^2 y MSE [30]; el coeficiente R^2 mide la correlación entre los datos obtenidos por el modelo y los datos originales, mientras que el error al cuadrado MSE (*Mean Squared Error*) presenta el promedio de las diferencias cuadráticas entre el modelo y los datos originales.

Tabla 20. Estadísticos para las redes FA-I en la predicción del HC2 y S2.

N	R^2	MSE de entrenamiento	MSE de validación
2	0,317	1,24E-02	1,21E-02
4	0,774	7,53E-03	7,41E-03
6	0,868	4,17E-03	4,10E-03
8	0,940	1,63E-03	1,57E-03
10	0,957	1,02E-03	9,71E-04
12	0,969	6,50E-04	5,78E-04
14	0,968	6,71E-04	6,20E-04
16	0,967	7,32E-04	6,97E-04
18	0,975	5,17E-04	4,75E-04

Tabla 21. Estadísticos para las redes FA-II en la predicción del HC2 y S2.

N	R^2	MSE de entrenamiento	MSE de validación
2	0,185	1,84E-02	1,86E-02
4	0,546	1,61E-02	1,64E-02
6	0,708	1,26E-02	1,27E-02
8	0,735	1,23E-02	1,24E-02
10	0,724	1,25E-02	1,26E-02
12	0,733	1,24E-02	1,25E-02
14	0,729	1,24E-02	1,25E-02
16	0,738	1,23E-02	1,24E-02
18	0,762	1,19E-02	1,20E-02

Por otra parte, aunque la red FA-I con topología 9:18:2 presentó los mejores estadísticos, MSE y R^2 , las Figuras 21 y 22 que reportan el desempeño durante la validación, indican que para valores superiores de $N=12$ la variación en los estadísticos es mínima. Lo anterior indica que el número de neuronas óptimas para la capa oculta debe corresponder a 12 para obtener valores de predicción de HC2 y S2 que puedan ser de utilidad a nivel cuantitativo.

Figura 20. Variación del MSE con N durante la validación en la predicción del HC2 y S2 con redes FA-I






Figura 21. Variación del R² con N durante la validación en la predicción del HC2 y S2 con redes FA-II



Al comparar los resultados obtenidos con los trabajos desarrollados por Arce & Paz [13] y Lukec & Sertic [12] se observa que las tendencias de predicción son similares para el contenido de azufre en el producto hidrotratado (R^2 mayores a 0,9); cabe resaltar que los modelos propuestos por Arce *et al.* se desarrollaron para el hidrotratamiento de nafta de la refinería de PEMEX en México, con un conjunto de datos de 197 tomados cada día y los de Lukec *et al.* para el hidrotratamiento de gasóleo ligero (GLO) y gasóleo de vacío (GVO) de la refinería de Rijeka en Croacia, con un conjunto de datos de 220 (GLO) y 125 (GVO) tomados cada hora. En el presente trabajo las RNA difieren de las planteados por Arce *et al.* y Lukec *et al.* en cuanto al número de neuronas en la capa de entrada, oculta y de salida; estos autores obtuvieron modelos de red con topologías 7:5:4 y


6:6:1, en las Figuras 23 y 24 se observan las respectivas variables utilizadas. Las RNA desarrolladas en el presente trabajo tienen una capacidad predictora con un R^2 igual a 0,989 para el contenido de azufre en el producto hidrotratado, en comparación con las RNA propuestas por Arce *et al.* y Lukec *et al.* que obtuvieron respectivamente valores de R^2 iguales a 0,918; 0,9514 (GLO) y 0,9368 (GVO). La diferencia en las topologías y capacidad de predicción, puede deberse a la diferencia de variables de entrada y salida y al conjunto de datos utilizados.

Figura 22. Modelo de RNA planteado por Arce *et al.*



Fuente: Arce *et al.* (2009).

Figura 23. Variables de entrada y salida, modelos de RNA propuestos por Lukec *et al.*



Fuente: Lukec *et al.* (2007).

4.3. RNA PARA LAS CONDICIONES DE OPERACIÓN

La topología considerada para la predicción de las condiciones de operación fue de la forma 7: N: 3, donde 7 corresponde a la cantidad de variables de entrada, N el número de neuronas en la capa oculta y 3 las variables de salida Hidrógeno (H), diferencial de temperatura (dT) y presión (P) (Anexo A, Figura 38). Según la relación de la capa oculta – capa de entrada [25] [26], N debe ser menor o igual a 14. El desempeño de las diferentes RNA puede ser analizado en las Tablas 21 y 22; según estas tablas el desempeño de las redes es limitado para $N \leq 14$ con el mejor desempeño obtenido en la red FA-I y 14 neuronas en la capa interna. El aumento en N muestra que la mejora en los estadísticos de desempeño de las RNA es exiguo. Las Figuras 25–28 ilustran las tendencias obtenidas para los estadísticos de la etapa de predicción con la variación en el número de neuronas internas para FA-I y FA-II. De acuerdo a estas figuras, las redes FA-I presentan su mejor desempeño en la topología 7:22:3 para la cual la etapa de predicción de la presión es deficiente reportando un valor máximo de 0,027 para el R^2 de predicción (Figura 25); en lo referente al flujo de hidrógeno y el cambio de temperatura, R^2 reporta valores de predicción de 0,926 y 0,728, respectivamente. De otro lado, las redes FA-II muestran un desempeño inapropiado para la etapa de predicción de las variables respectivas (Figura 26). Según las Figuras 27 y 28, las redes FA-I y FA-II reportan valores de *MSE* comparables. Resumiendo lo anterior, la predicción del flujo de hidrógeno, el cambio de temperatura en la zona de reacción y la presión utilizando una sola red, ya sea FA-I o FA-II, reporta aplicaciones que pueden ser de utilidad desde una valoración cualitativa, pero sólo para la predicción del flujo de hidrógeno.

Tabla 22. Desempeño de las RNA FA-I en la predicción de H, dT y P.

N	R²	MSE de entrenamiento	MSE de validación
2	0,753	6,79E-03	6,89E-03
4	0,848	4,40E-03	4,40E-03
6	0,858	4,13E-03	4,12E-03
8	0,872	3,17E-03	3,15E-03
10	0,900	2,97E-03	2,98E-03
12	0,911	2,66E-03	2,64E-03
14	0,919	2,42E-03	2,43E-03
16	0,923	2,32E-03	2,35E-03
18	0,928	2,18E-03	2,15E-03
20	0,930	2,10E-03	2,07E-03
22	0,934	2,00E-03	2,03E-03

Tabla 23. Desempeño de las RNA FA-II en la predicción de H, dT y P.

N	R²	MSE de entrenamiento	MSE de validación
2	0,741	7,15E-03	7,28E-03
4	0,780	6,33E-03	6,41E-03
6	0,790	6,15E-03	6,24E-03
8	0,827	5,50E-03	5,58E-03
10	0,805	5,82E-03	5,89E-03
12	0,812	5,78E-03	5,83E-03
14	0,823	5,44E-03	5,52E-03
16	0,829	5,38E-03	5,45E-03
18	0,833	5,38E-03	5,42E-03
20	0,832	5,40E-03	5,47E-03
22	0,837	5,29E-03	5,37E-03

Figura 24. Variación de R^2 vs N en las redes FA-I para la predicción de H, dT y P.




Figura 25. Variación de R^2 vs N en las redes FA-II para la predicción de H, dT y P.




Figura 26. Variación de MSE vs N en las redes FA-I para la predicción de H, dT y P.





Figura 27. Variación de MSE vs N en las redes FA-II para la predicción de H, dT y P.



Por las razones expuestas anteriormente, se decidió probar otro modelo de red neuronal, donde la presión fuera una variable de entrada y no una variable de salida. De esta forma, se buscó entrenar una RNA para estimar el flujo de hidrógeno y el cambio de temperatura en la zona de reacción. Este modelo de red se desarrolló con la topología 8:N:2, donde 8 era el número de variables de entrada, N el número de neuronas en la capa oculta y 2 el número de salidas (Anexo A, Figura 39).

Según los resultados (Anexo B), no se encontró un coeficiente de determinación aceptable para las RNA dentro del límite establecido por la regla de la capa de entrada – capa oculta [25] [26] con $N \leq 16$. Una mayor cantidad de neuronas en la capa oculta fue utilizada para la topología 08:22:02 con función de activación FA-I; el desempeño de las RNA entrenadas reporta mejores coeficientes de determinación y valores de *MSE* para el flujo de hidrógeno y el cambio de temperatura que el modelo planteado inicialmente (R^2 de 0,930 y 0,759; y valores *MSE* de 1,11E-03 y 2,92E-03, respectivamente).

4.4. RNA PARA LA PREDICCIÓN DE VARIABLES INDIVIDUALES

Las variables de salida en los casos de las secciones anteriores fueron predichas utilizando una topología 9:N:1, en donde 9 corresponde a las variables de entrada, N las neuronas de la capa oculta y 1 a la neurona de salida para la propiedad en turno (Anexo C); según la regla de la capa de entrada-capas ocultas [25] [26], N debe tomar valores menores o iguales a 18. Los resultados mostrados en las Tablas 23 y 24, reportan que la capacidad predictiva de las redes tipo FA-I supera notablemente a las de tipo FA-II. Asimismo, la predicción del cambio de temperatura en la zona de reacción mejora respecto a lo obtenido en la sección anterior. También mejoraron las predicciones para cada una de las variables por separado, en comparación con las RNA planteadas con más de una variable de salida. Es importante mencionar que la predicción de dT requiere de una mayor cantidad de neuronas en la capa oculta que para las otras variables, con el fin de obtener un coeficiente de correlación y un MSE aceptables.

Por otra parte, no se plantearon RNA para predecir la presión ya que como se observó anteriormente, no fue posible obtener una predicción aceptable; al analizar esta variable (Anexo D, Figura 52, Tabla 18), se encontró que la presión presentaba cambios bruscos en la tendencia habitual de los datos medidos, lo cual dificulta el entrenamiento de una RNA. En la Tabla 25 se exponen los mejores modelos de predicción obtenidos en el presente trabajo, donde cabe resaltar, que los modelos con configuración *logsig-purelin* en la capa oculta y de salida, fueron los que arrojaron los mejores resultados tanto en el entrenamiento como en la validación.

Tabla 24. Validación de los modelos de red neuronal con funciones de activación FA I.

Variable a predecir	Topología	R ²	MSE de entrenamiento	MSE de validación
S2	9:14:1	0,997	1,75E-04	1,21E-04
HC2	9:16:1	0,974	4.62E-04	4.57E-04
RR	9:14:1	0,993	1.23E-04	1.27E-04
H	9:16:1	0,942	8.85E-04	9.22E-04
dT	9:24:1	0,814	2.55E-03	2.25E-03

Tabla 25. Validación de los modelos de red neuronal con funciones de activación FA II.

Variable a predecir	Topología	R ²	MSE de entrenamiento	MSE de validación
S2	9:10:1	0,718	1.91E-02	1.90E-02
HC2	9:14:1	0,804	4.52E-03	4.84E-03
RR	9:14:1	0,838	4.87E-03	5.15E-03
H	9:12:1	0,758	4.97E-03	4.79E-03
dT	9:20:1	0,427	8.11E-03	8.64E-03

Tabla 26. Resumen de las mejores RNA obtenidas.

Variable(s) a predecir	Topología	R ²	MSE de entrenamiento	MSE de validación
S2 – HC2	9:12:02	0,969	6,50E-04	5,78E-04
H – dT - P	7:22:03	0,934	2,00E-03	2,03E-03
H - dT	8:22:02	0,928	1,99E-03	2,02E-03
S2	9:14:01	0,997	1,75E-04	1,21E-04
HC2	9:16:01	0,974	4.62E-04	4.57E-04
RR	9:14:01	0,993	1.23E-04	1.27E-04
H	9:16:01	0,942	8.85E-04	9.22E-04
dT	9:24:01	0,814	2.55E-03	2.25E-03


4.5 PRUEBAS DE VALIDACIÓN ADICIONALES

Según la búsqueda de literatura realizada, no existe evidencia bibliográfica donde se referencie la predicción de las variables de operación en el proceso de hidrotratamiento a partir del contenido de azufre en el acpm de salida. Esto refleja la oportunidad para seguir investigando en este tipo de condiciones y sus posibles resultados en pro de mejoras técnicas y de ingeniería.

Una prueba de validación adicional para la temperatura de reacción y el flujo de hidrógeno fue realizada sobre los datos tomados de la ventana operacional entre enero y mayo de 2016 tal como se aprecia en la Tabla 26. El entrenamiento de la red neuronal tipo 8:22:2 con función de activación FAI reportó que el cambio de temperatura en la zona de reacción fue ajustado con un R^2 de 0.549, mientras que el flujo de hidrógeno presentó un R^2 de 0.892. Lo anterior sugiere que la ventana de operación asumida en la validación adicional contiene esquemas operacionales no considerados para el entrenamiento de las RNA de la sección anterior.


Para esta prueba adicional se contó con aproximadamente 5000 datos de cada una de las variables analizadas. La figura 29 muestra el diagrama de dispersión para el flujo de hidrógeno en los datos utilizados para la validación extra de la red neuronal. En el eje Y está consignado el flujo de hidrógeno en mol/min y en el eje X se consigna la cantidad de datos aleatorios que fueron tenidos en cuenta.

Figura 28. Diagrama de dispersión para el flujo de hidrógeno (H) en la validación extra



Por otra parte, para la evaluación del cambio de temperatura en la zona de reacción se analiza que la muestra tiene una tendencia más estable producto del mismo control del proceso para mantener las condiciones operativas requeridas para la integridad en los equipos y evitar la desactivación del catalizador por aumentos inesperados de temperatura. En la misma figura 30 se consigna en el eje de las Y el diferencial de temperatura (dT) en ° F y en el eje de las X los datos aleatorios del muestreo.

Figura 29. Diagrama de dispersión para el cambio de temperatura en la zona de reacción (dT) en la validación extra



En el anexo E se encuentran recopilados los diferentes diagramas utilizados para la prueba extra de la red neuronal

Tabla 27. Resumen de estadísticos utilizados en la validación extra

RESUMEN DATOS USADOS EN LA VALIDACIÓN EXTRA				
SÍMBOLO	VALOR MÍNIMO	VALOR PROMEDIO	VALOR MÁXIMO	DESVIACIÓN ESTANDAR
HC1	34296,367	63672,641	52736,814	5484,277
PFB	719,100	759,700	737,188	8,346
PIB	333,500	414,900	390,356	19,755
API	28,405	30,899	29,710	0,391
S1	3985,000	5603,000	4786,671	347,802
H	106,921	142,585	126,216	5,790
RR	245,554	557,061	419,606	54,699
T1	627,008	651,832	636,058	3,419
dT	36,129	46,895	42,010	1,558
P	677,002	688,046	684,919	0,659
HC2	28536,016	60276,828	47715,705	5424,023
S2	5,000	50,000	26,989	10,611

La clasificación en diferentes esquemas operacionales de la información presentada en la ventana operacional de la validación adicional fue efectuada por medio del uso del método de clasificación denominado *k-mean* y del análisis por componentes principales. La figura 29 muestra las clases encontradas representadas en las coordenadas de los scores para los dos primeros componentes principales (los dos primeros componentes principales reproducen el 54% de la varianza de los datos históricos analizados). Según lo anterior, los datos pueden ser clasificados en tres clases caracterizadas por valores diferentes en sus variables de entrada. Un análisis respecto a las tendencias de las variables de entrada refleja que las clases encontradas se forman según los valores para el flujo de carga y el punto inicial de ebullición (IBP) de la misma (Figura 30). Según, la figura 30 la operación de la unidad HDT presenta un desempeño diferente según el flujo de carga (carga baja o carga alta); la carga baja presenta un flujo de

alimentación con valores entre 31853 Bls/día y 51417 Bls/día, mientras la carga alta muestra valores de flujo de alimentación entre 51418 Bls/día y 64941 Bls/día. También, de la figura 30 se infiere que la unidad opera diferente en carga alta según el IBP de la misma.

Con base a los resultados anteriores, se realizó una división del comportamiento de las variables a bajo y alto flujo, los estadísticos para las variables en el análisis a bajo flujo de operación son mostrados en la Tabla 27. En este análisis se detalla que a pesar de condiciones de baja carga se llega a un máximo de contenido de azufre de 50 ppm, que es alto con respecto al máximo contenido a carga mayores, y además es mayor a pesar de tener menor punto de ebullición inicial, pues a mayor contenido de livianos, debería ser menor el contenido de azufre. Los resultados muestran que para estas condiciones de proceso, con un comportamiento de baja carga y bajo punto inicial de ebullición tienen un mayor contenido de azufre a la salida, esto se debe posiblemente a que durante estas corridas la operación de las unidades de refinación contaron con carga de crudo con mayor porcentaje de LCT en la mezcla, que se traduce en una mayor producción de Jet-A1 en la unidad de crudo, el cual es cargado por la unidad de hidrotratamiento y por ende se baja el punto inicial de ebullición, pero a mayor contenido de LCT, se aumenta la presencia de fracciones pesadas en el diésel con contenido de azufre de difícil remoción debido a estructura molecular por efectos estéricos de anillos de bencenos alrededor del azufre. Además, dichas fracciones alcanzan puntos entre 740 y 750 °F, razón por la cual se llegan a obtener punto de ebullición finales mayores al promedio de 725 a 730°F. Es preciso aclarar que una mayor presencia de fracciones livianas como el jet en la carga a hidrotratamiento hace que la velocidad de reacción sea más baja debido al menor contenido de compuestos azufrados, que a su vez impacta en la integración energética de la unidad por un mayor consumo de energía en el horno para poder cumplir con la temperatura requerida en el precalentamiento para la reacción.

Tabla 28. Resumen estadístico para las variables de operación a baja carga

[Carga de HC1 Baja]				
SÍMBOLO	VALOR MÍNIMO	VALOR PROMEDIO	VALOR MÁXIMO	DESVIACIÓN ESTANDAR
HC1	34296,367	47092,266	51417,691	4355,381
PFB	719,100	733,298	748,400	7,064
PIB	333,500	386,338	414,900	22,005
API	28,706	29,776	30,899	0,410
S1	3985,000	4832,829	5603,000	418,375
H	107,858	128,621	142,585	6,431
RR	245,554	367,543	463,208	43,467
T1	628,533	634,052	648,186	2,462
dT	36,129	41,749	46,428	2,016
P	677,002	684,951	687,487	0,608
HC2	28536,016	42387,026	48955,414	4461,921
S2	6,500	24,411	50,000	12,465

El comportamiento de la unidad para una carga alta en el flujo de hidrocarburo es mostrado en la Tabla 28, donde se observa comportamiento similar a la tabla anterior, en cuanto a los rangos de contenido de azufre tanto a la entrada como a la salida, la diferencia se refleja en la carga con lo cual se observa un incremento en el punto final de ebullición, por lo cual se debe a mayor flujo en el reactor y por ende hacia la torre fraccionadora de productos hidrotratados, lo cual favorece el incremento de fracciones pesadas, y a su vez una mayor carga genera un arrastre de productos livianos hacia el fondo debido al presionamiento de la torre y por absorción de vapores livianos en fracciones pesadas.

Tabla 29. Rango de operación de la unidad con alto flujo de hidrocarburo

[Carga de HC1 Alta]				
SÍMBOLO	VALOR MÍNIMO	VALOR PROMEDIO	VALOR MÁXIMO	DESVIACIÓN ESTANDAR
HC1	51419,719	56279,510	63672,641	2121,134
PFB	723,400	739,630	759,700	8,162
PIB	333,500	392,877	414,900	17,746
API	28,405	29,669	30,350	0,373
S1	3985,000	4757,700	5446,000	291,373
H	106,921	124,707	136,532	4,766
RR	379,530	452,282	557,061	30,250
T1	627,008	637,318	651,832	3,333
dT	36,308	42,175	46,895	1,153
P	677,649	684,900	688,046	0,689
HC2	40424,094	51060,152	60276,828	2526,214
S2	5,000	28,607	49,000	8,888

Debido al comportamiento de la unidad a alta carga y su variación de acuerdo al punto inicial de ebullición se presentan los datos estadísticos de estas condiciones de proceso. Para las Tablas 29 y 30 se observa que el incremento de compuestos livianos en la carga a la unidad disminuye el punto inicial de ebullición. Se analiza que más alto contenido de azufre incrementa el azufre final en la salida de la unidad, donde posiblemente existiera menor contenido de compuestos azufrados de difícil remoción, a su vez los efectos predominantes son; que alto contenido de azufre a la entrada se tendrán valores de azufre más alto en la salida, incremento de compuestos livianos a la entrada disminuye el punto de ebullición de acpm a tratar. Esto hace la diferencia con respecto a lo analizado en las tablas anteriores (Tablas 27 y 28).

Tabla 30. Resumen estadístico de operación a alto flujo y bajo punto inicial de ebullición.

[Carga de HC1 Alta con PIB Bajo]				
SÍMBOLO	VALOR MÍNIMO	VALOR PROMEDIO	VALOR MÁXIMO	DESVIACIÓN ESTANDAR
HC1	51423,656	56746,271	63672,641	2321,535
PFB	723,400	737,890	755,100	7,631
PIB	333,500	370,061	383,500	10,306
API	28,412	29,828	30,350	0,435
S1	4445,000	4963,026	5446,000	237,974
H	106,921	123,511	134,756	4,860
RR	406,956	460,621	545,909	33,823
T1	630,204	637,267	651,832	3,145
dT	36,308	41,994	45,874	1,143
P	679,945	684,961	688,046	0,515
HC2	40424,094	51073,957	57496,738	2857,828
S2	14,000	31,548	49,000	7,651

Tabla 31. Resumen estadístico de operación a alto flujo y alto punto inicial de ebullición

[Carga de HC1 Alta con PIB Alto]				
SÍMBOLO	VALOR MÍNIMO	VALOR PROMEDIO	VALOR MÁXIMO	DESVIACIÓN ESTANDAR
HC1	51419,719	56048,997	63463,906	1975,131
PFB	726,300	740,489	759,700	8,280
PIB	393,100	404,144	414,900	5,821
API	28,405	29,590	30,344	0,308
S1	3985,000	4656,299	5195,000	260,336
H	111,781	125,298	136,532	4,606
RR	379,530	448,163	557,061	27,407
T1	627,008	637,343	647,650	3,423
dT	36,665	42,264	46,895	1,148
P	677,649	684,869	687,616	0,759
HC2	42646,617	51053,335	60276,828	2345,945
S2	5,000	27,155	43,000	9,097

Según la clasificación anterior, tres redes neuronales fueron entrenadas para evaluar el comportamiento de las variables de proceso en relación a la influencia

del flujo total de la carga de acpm y sus valores respectivos de IBP. El diseño de cada red contó con un amplio número de datos de cada variable para entrenamiento y para validación. Las variables de proceso predichas fueron flujo de hidrógeno y cambio de temperatura en la zona de reacción.

Figura 30. Gráfica de los scores para los dos primeros componentes principales. Los diferentes símbolos y colores representan las clases obtenidas por el método k-mean considerando la distancia euclidiana





Figura 31. Variación del punto inicial de ebullición vs el flujo de carga; las clases se indican con los diferentes símbolos y colores obtenidas por el método k-mean considerando la distancia euclidiana



El desempeño de la RNA para la clase de carga alta y bajo IBP en la predicción del cambio en la temperatura se presenta en la Tabla 31. Según la Tabla 31, el flujo de hidrógeno mostró un R^2 de 0.913 para el entrenamiento, R^2 de 0.915 en la primera validación, R^2 de 0.90 con una validación externa (R^2 promedio de 0.909). De otro lado, una RNA para la predicción en conjunto del flujo de hidrógeno y el cambio en la temperatura fue entrenada con los datos clasificados con baja carga de alimentación y bajo IBP; la Tabla 32 reporta el desempeño de esta red; según esta tabla, la RNA presentó valores de R^2 de 0.965 para el entrenamiento, 0.964 en la primera validación y 0.964 con una validación (R^2 promedio de 0.964) para la predicción del flujo de hidrógeno. Para la predicción del cambio en la temperatura de reacción, la tabla 32 reporta valores de R^2 de 0.880 para el entrenamiento, 0.889 en la primera validación y 0.892 con una validación externa, reflejando un R^2 promedio de 0.887. Los valores de desempeño obtenidos con la RNA para esta clase soportan la aplicación cuantitativa de la red para la predicción del flujo de

hidrógeno y la aplicación cualitativa de la red para la predicción del cambio en la temperatura de reacción.

Tabla 32. Predicción de dT con carga de HC baja

	Redes Predicción dT		
	Clase 0 [Carga de HC1 Baja]		
	Entrenamiento	Validación	Validación Externa
R.cuadrado	0,913	0,915	0,900
R.cuadrado Promedio	0,909		

Tabla 33. Predicción de H y dT con carga de HC baja

	Redes Predicción H y dT					
	Clase 0 [Carga de HC1 Baja]					
	H			dT		
	Entrenamiento	Validación	Validación Externa	Entrenamiento	Validación	Validación Externa
R.cuadrado	0,965	0,964	0,964	0,880	0,889	0,892
R.cuadrado Promedio	0,964			0,887		

Por otra parte, dos RNA para la predicción del flujo de hidrógeno y el diferencial de temperatura en la zona de reacción, fueron entrenadas para las restantes clases (Figuras 31 y 32) considerando su relación con el punto inicial de ebullición. El entrenamiento de la RNA, considerando carga de alimentación alta sin discriminar en el IBP para la predicción del flujo de hidrocarburo y el diferencial de temperatura en la zona de reacción reporta un desempeño regular en su entrenamiento (Tabla 33); para el flujo de hidrógeno el desempeño de la RNA reportó R^2 de 0.896 para el entrenamiento, R^2 de 0.881 en la primera validación y R^2 de 0.886 con una validación externa, reflejando un R^2 promedio de 0.888. La misma RNA para la predicción del cambio de temperatura muestra los siguientes valores de R^2 : 0.584 en entrenamiento, 0.556 para validación y 0.588 para validación externa. Los desempeños de la red sólo soportan la aplicación de la misma para análisis cualitativos del flujo de hidrógeno en la unidad HDT.

Tabla 34. Predicción de H y dT con carga de HC alta

	Redes Predicción H y dT					
	Clase 1 [Carga de HC1 Alta]					
	H			dT		
	Entrenamiento	Validación	Validación Externa	Entrenamiento	Validación	Validación Externa
R.cuadrado	0,896	0,881	0,886	0,584	0,556	0,588
R.cuadrado Promedio	0,888			0,576		

Con el mismo comparativo de las redes y de acuerdo al análisis por componentes principales (PCA) presentado, se estableció una siguiente evaluación, donde se tuvo en cuenta alto flujo de acpm a la entrada de la unidad con bajos valores en el punto inicial de ebullición. La predicción del cambio de temperatura fue la siguiente: entrenamiento R^2 de 0.621, validación R^2 de 0.608 y para validación externa R^2 de 0.609, con un promedio de R^2 de 0.613 (Tabla 34). El desempeño de la RNA considerando sólo valores de IBP altos mejora, reportando un valor promedio de R^2 de 0.749 (Tabla 35). Aunque los desempeños mejoran respecto a la no consideración del PIB, los desempeños de las redes (Tablas 34 y 35) no soportan su aplicación para análisis del cambio en la zona de reacción en las condiciones de flujo de alimentación elevado. El bajo desempeño de las RNA en la predicción del cambio en la temperatura de reacción puede estar relacionado con la variabilidad de los diversos crudos que son destilados como materia prima para la obtención del acpm antes del proceso de hidrot ratamiento. Esta variabilidad requiere el uso de nuevas variables de entrada que reflejen la composición del acpm para el rentrenamiento de las RNA.

Tabla 35. Predicción de dT con carga de HC alta y bajo PIB

	Redes Predicción dT		
	Clase 0 [Carga de HC1 Alta con PIB Bajo]		
	Entrenamiento	Validación	Validación Externa
R.cuadrado	0,621	0,608	0,609
R.cuadrado Promedio	0,613		

Tabla 36. Predicción de dT con carga de HC alta y alto PIB.

	Redes Predicción dT		
	Clase 2 [Carga de HC1 Alta con PIB Alto]		
	Entrenamiento	Validación	Validación Externa
R.cuadrado	0,773	0,732	0,743
R.cuadrado Promedio	0,749		

De otro lado, con carga de hidrocarburo alto y alto punto inicial de ebullición, la predicción del flujo de hidrógeno muestra resultados satisfactorios con un R^2 promedio de 0.951, lo cual soporta la aplicación de la RNA respectiva en análisis de tipo cuantitativo (Tabla 36).

Tabla 37. Predicción de H y dT con carga de HC alta y alto PIB.

	Redes Predicción HydT					
	Clase 2 [Carga de HC1 Alta con PIB Alto]					
	H			dT		
	Entrenamiento	Validación	Validación Externa	Entrenamiento	Validación	Validación Externa
R.cuadrado	0,955	0,953	0,945	0,676	0,648	0,666
R.cuadrado Promedio	0,951			0,663		

Al comparar el comportamiento de las redes neuronales con respecto al reflejado en la simulación de hidrot ratamiento, es posible afirmar que se pueden establecer los requerimientos de azufre en HDT que conlleven a una adecuada producción de

B2E. El aporte fundamental de la red neuronal artificial, es por un lado que a partir de los requerimientos de calidad de diésel B₂E, se pueda predecir las condiciones operativas de la unidad de hidrotreatmento que conlleven a un diésel con características de azufre más acordes a las establecidas por la normatividad. Por otro lado, los ajustes operacionales para que la unidad trabaje en los puntos óptimos de control, permitirán a las diferentes áreas (Planeación y programación, ingeniería de proceso y operaciones) que tienen incidencia en el proceso, evaluar los beneficios por una operación más estable, con control en la severidad y operación más rentable en beneficios económicos por un mayor y mejor aprovechamiento de los insumos, recursos y materiales.

Lo anterior y las demás observaciones, sustentan que el tratamiento estadístico, la red neuronal y la simulación realizada resultan complementarias para entender la variabilidad del proceso de hidrotreatmento y la preparación de diésel como producto final, siendo necesario implementar dichas herramientas para la predicción del comportamiento de todo el proceso de transformación del diésel. Además, que todo esto permite definir el comportamiento global desde la refinación hasta la preparación de producto final para llegar a los más altos estándares de preparación de dicho combustible, reduciendo pérdidas y proyectando una disminución de reprocesos en un 80%.

5. MODELO MATEMÁTICO DE OPTIMIZACIÓN

5.1. ÍNDICES DE MEZCLA

Las preparaciones de diésel deben cumplir especificaciones de calidad y características que son propias de acuerdo al componente utilizado. Algunas de estas propiedades son obtenidas mediante mezclas lineales, sin embargo, otras propiedades tienen un comportamiento no lineal en el proceso de mezclado. De otro lado, las mezclas no lineales se relacionan de acuerdo a funciones matemáticas; para estos casos como lo define Verruschi [31], “Como solución alternativa se utiliza una propiedad empírica relacionada llamada número o índice de mezcla, el cual se mezcla linealmente”. El índice de mezcla en las propiedades de los componentes se evalúa experimentalmente para determinar aquellas propiedades con comportamiento no lineal, que se pueda verificar y obtener la relación de la propiedad con el producto final. Este conocimiento, los análisis y los resultados hacen parte del *Know-How* de la Gerencia Complejo Barrancabermeja y se mantiene como reserva propia de la compañía.

5.2. RUTEO DE LOS COMPONENTES

Luego del proceso de destilación primaria del crudo se obtiene una corriente intermedia de las 5 unidades topping. Dicha corriente es el acpm de alto azufre (HS) que cuenta con un contenido de azufre superior a los 5000 ppm. Este acpm es almacenado en el tanque establecido para tal fin y es la corriente de carga a la unidad de hidrot ratamiento. De la descarga de la bomba de transferencia a la planta, se deriva una línea adicional de 3” que tiene llegada a la entrada al cabezal

de mezcla del blending de diésel y está habilitada para ser utilizada cuando la preparación de diésel lo requiera.

Después de ser tratado el acpm de alto azufre a través de la unidad de hidrotreamiento se convierte en una corriente con bajo contenido de azufre (con valores promedio entre 12 y 30 ppm) que es almacenado en el K-805. De allí es bombeado hacia la matriz de blending donde es mezclado con otros componentes para la preparación del diésel comercial. El ingreso de este componente es controlado por un sistema de control regulatorio de mezcla.

Otro de los componentes de gran importancia es el ACEM. Este acpm llega a la refinería a través del oleoducto proveniente de pozos colorados y es almacenado en tanques ubicados en el área de casa de bombas 5. El componente es importado y se utiliza para cumplir la demanda de diésel del país. Se aprovecha en las preparaciones del blending por su bajo contenido de azufre y baja destilación.

Los componentes asociados a la preparación de diésel en la Gerencia Refinería Barrancabermeja están definidos de la siguiente manera:

- *ACPM Hidrotreamido (ULSD_HDT) o ACPM Pesado HDT*
- *ACPM Bajo Azufre (ACPM LS)*
- *JET sin tratamiento (JST)*
- *Nafta Pesada (NAF_PES UOP II)*
- *Virginoil (VIRG)*
- *Aceite Liviano De Ciclo. ALC modelo IV*
- *ACPM ULS Importado (ACPM_IMP)*
- *ACPM Alto Azufre (ACPM_HS)*
- *JET ULS Hidrotreamido (JET_ULS) o ACPM Liviano HDT*
- *Biodiesel.*

Los componentes de mayor aporte en el cabezal de blending y que frecuentemente pueden ser utilizados para la preparación del diésel son:

ACPM Hidrotratado (ULSD_HDT)

ACPM ULS Importado (ACPM_IMP)

Jet ULS Hidrotratado (ACPM LIVIANO HDT)

Biodiesel

Adicional a los componentes mencionados anteriormente se cuenta con otras corrientes que en ocasiones son utilizadas en la preparación de diésel. Este proceso se lleva a cabo de acuerdo al plan establecido por la coordinación de planeación de la producción y necesidades operativas para tener dentro de los rangos de control las especificaciones del producto. Los componentes de menor aporte en el blending y que eventualmente se pueden direccionar hacia los cabezales de mezcla son:

Virginoil.

Aromáticos pesados

Nafta Pesada

ACPM Alto Azufre (ACPM_HS)

5.3. MODELO MATEMÁTICO

La razón de ser del blending de diésel de la Gerencia Refinería Barrancabermeja (GRB) es maximizar la producción de diésel B₂E, cumpliendo con la demanda del país y aprovechando las corrientes de menor valor agregado. Adicionalmente busca optimizar el margen de refinación dando cumplimiento a las especificaciones de calidad establecidas por las regulaciones nacionales y

reduciendo el regalo de calidad en parámetros como destilación, azufre, viscosidad cinemática y biocombustibles.

Para satisfacer un proceso de optimización se hace necesario definir los rangos de aplicación dentro de los cuales se mueven las variables que cumplen con las especificaciones requeridas. En el caso particular de las preparaciones del diésel se buscó analizar aquellas que mayor incidencia económica tienen en el margen de refinación de la GRB.

Las propiedades de mayor control en el diésel comercial y que tienen impacto significativo en el margen de refinación de la refinería son la destilación y el contenido de azufre. En la destilación el rango máximo establecido por la legislación colombiana es 380 ° C.

Para el contenido de azufre el máximo valor establecido es 50 ppm. Como política empresarial y en aras de garantizar la calidad del producto, la GRB prepara el diésel con un máximo contenido de azufre en 38 ppm, lo cual permite proteger producto en caso de alguna eventualidad en el transporte.

Con el respaldo de los compromisos establecidos por la organización y estableciendo el plan de entrega a los diferentes clientes, se define la función objetivo para el proceso. En otros términos, es donde se define los rangos máximos y mínimos de una ecuación de programación lineal.

Para llevar a cabo el modelo matemático se tiene en cuenta las restricciones del proceso a tratar y las variables que hacen parte de dicho proceso.

Según Ramos Et al, (2010) “Resolver un problema de optimización consiste en encontrar el valor que debe tomar las variables para hacer optima la función objetivo satisfaciendo el conjunto de restricciones”. [32]

El presente documento establece la siguiente función objetivo:

$$F. Obj = PF * F - \sum (PG_n * F_n)$$

F. Obj. = margen de ganancia por preparación de diésel.

PF = precio por barril de producto final.

PG_n = precio por barril de componente de preparación.

La maximización de la función objetivo está sujeta a las siguientes restricciones a:

- Balance de masa:

$$F - \sum F_n = 0$$

- Restricción para el azufre:

$$S * \sum (F_n * \rho_n) - \sum (F_n * \rho_n * S_n) = 0$$

- Restricción para T95:

$$BiT95 * F - \sum (BiT95_n * F_n) = 0$$

- Restricción para la viscosidad cinemática:

$$Bivis * F - \sum (Bivis_n * F_n) = 0$$

- Restricción para el punto de inflamación:

$$BiFP * F - \sum (BiFP_n * F_n) = 0$$

- Restricción para el índice de cetano:

$$Ci * F - \sum Ci_n * F_n = 0$$

- Restricciones para las variables:

$$Fi^L \leq Fi, \quad Fi^S \geq Fi$$

$$Si \geq 25, \quad SF \leq 35$$

$$BiT95 \geq 0.9036, \quad BiT95 \leq 0.9663$$

$$Bivis \leq 13.91, \quad Bivis \leq 18.369$$

$$Bi FP \leq 0.251$$

$$Ci \geq 45$$

Donde:

F_n = flujo de cada componente i .

$BiT95$ = índice de mezcla de la temperatura de destilación del 95% por cada.

S = contenido de azufre.

Ci = índice de cetano.

PF = Precio del diésel preparado.

$Bivis$ = índice de mezcla para viscosidad.

$BiFP$ = índice de mezcla de flash point.

S_F = contenido de azufre en el producto.

S_n = contenido de azufre por cada componente.

n = Diésel de bajo azufre importado (ULSD), Diésel hidrotratado (DHT),
Componente hidrocraqueado (UNI), Virginoil (VO), Jet de HDT (Jet HDT).

La preparación de diésel es directamente proporcional a la cantidad de componentes utilizados en la mezcla desde el área de blending y que buscan garantizar el programa de producción establecido para satisfacer el plan volumétrico de entregas al país.

$$F \text{ Diésel} = F \text{ Bio} + F_{ULSD} + F_{HDT} + F_{UNI} + F_{VO}$$

Donde:

$F \text{ Diésel}$: Es el flujo total de diésel preparado

$F \text{ Bio}$: Es el flujo total de componente biodiesel utilizado.

F ULSD: Es el flujo total de acpm importado en la preparación.

F HDT: Es el flujo total de acpm hidrotratado adicionado.

F UNI: Es el flujo total de acpm de UNIBON utilizado.

F VO: Es el flujo total de nafta pesada dosificada en la preparación.

De igual forma para garantizar que el diésel preparado cumpla con las especificaciones de calidad determinadas por la legislación y las normas de calidad del país se ha definido dentro del presente documento las siguientes condiciones de acuerdo a las características de los componentes y las variables de preparación que presenta el proceso.

Para el caso particular de la preparación de diésel con los flujos arriba mencionados, se determinaron las siguientes ecuaciones para la optimización, según el modelo planteado anteriormente:

Maximizar ingresos F. $Obj = PF * F - \sum (PG_n * F_n)$

Sujeto a.

Restricción para el azufre:

$$\rho X_s * F_{Di} = \rho X_{SBio} * F_{Bio} + \rho X_{SULSD} * F_{ULSD} + \rho X_{SHDT} * F_{HDT} + \rho X_{SUNI} * F_{UNI} + \rho X_{SVO} * F_{VO}$$

Donde

ρ es la densidad

X_s es la fracción de azufre

F es el flujo de cada componente y del producto.

Restricción para la destilación:

$$\begin{aligned} \text{BiDiesel} * T95\text{Diesel} * F \text{ Diesel} \\ = \text{BiBio} * T95\text{Bio} * F\text{Bio} + \text{BiULSD} * T95\text{ULSD} * F\text{ULSD} + \text{BiHDT} \\ * T95\text{HDT} * F \text{ HDT} + \text{BiUNI} * T95\text{UNI} * F \text{ UNI} + \text{BiVO} * T95\text{VO} \\ * F \text{ VO} \end{aligned}$$

Donde

Bi es el índice de mezcla de cada componente y del producto

T95 es la destilación de cada componente y del producto

F es el flujo de cada componente y del producto

Restricción para la viscosidad cinemática:

$$\begin{aligned} \text{BiDiesel} * \vartheta\text{Diésel} * F \text{ Diesel} \\ = \text{BiBio}\vartheta\text{Bio} * F\text{Bio} + \text{BiULSD} * \vartheta\text{ULSD} * F\text{ULSD} + \text{BiHDT} * \vartheta\text{HDT} \\ * F \text{ HDT} + \text{BiUNI} * \vartheta\text{UNI} * F \text{ UNI} + \text{BiVO} * \vartheta\text{VO} * F \text{ VO} \end{aligned}$$

Donde

Bi es el índice de mezcla de cada componente y del producto,

ϑ es la viscosidad cinemática de cada componente y del producto

F es el flujo de cada componente y del producto

Restricción para el índice de cetano:

$$\begin{aligned} \text{BiDiesel} * ci\text{Diésel} * F \text{ Diesel} \\ = \text{BiBio}ci\text{Bio} * F\text{Bio} + \text{BiULSD} * ci\text{ULSD} * F\text{ULSD} + \text{BiHDT} * ci\text{HDT} \\ * F \text{ HDT} + \text{BiUNI} * ci\text{UNI} * F \text{ UNI} + \text{BiVO} * ci\text{VO} * F\text{VO} \end{aligned}$$

Donde

B_i , es el índice de mezcla de cada componente y del producto,

c_i , es el índice de cetano de cada componente y del producto ,

F , es el flujo de cada componente y del producto

El apoyo del área de economía y gestión permitió realizar un análisis económico de cada una de las corrientes que entran en la preparación y el valor potencialmente económico que este refleja en cada una de las preparaciones.

5.4 EVALUACIÓN DEL MODELO PROPUESTO

El modelo de optimización fue codificado en EXCEL para el uso de la herramienta solver para la obtención del punto solución por programación lineal. Los precios utilizados para determinar el costo de preparación fueron suministrados por el área de economía y gestión. Es de aclarar que en caso del biodiesel es posible encontrar la información económica y volúmenes de producción a través de la página del ministerio de minas y energía que regula el precio de los combustibles. A partir de la herramienta de Excel se logró realizar el análisis de las preparaciones de diésel con la optimización de la matriz de blending y reflejando el potencial económico de los mismos. El archivo de Excel codificado fue utilizado para el análisis de diferentes escenarios de preparación de diésel.

Escenario 1. Para preparaciones con destilación en 380° C

Para llevar a cabo esta evaluación se tuvo en cuenta el requerimiento comercial y las condiciones establecidas para el cálculo de destilación con valores de T-95 en 380 objetivo. El tiempo de esta preparación para dicho estudio comprendió los meses de enero hasta abril del año 2016. Como se aprecia en la Tabla 37, la

preparación objetivo del producto preparado reflejaba resultados en azufre de 14 ppm y T-95 en 373.8 °C. De acuerdo a los resultados en el momento de la preparación que se obtuvieron por laboratorio y el histórico de flujos obtenidos por los sistemas de medición de la matriz de blending

Tabla 38. Resultados de los análisis de la preparación real por modelo de optimización

PARÁMETRO	JET HDT	HDT	ACEM	Biodiesel	Virginoil	ACPM Unibon	TOPPING	DIESEL REGULAR
Azufre, ppm	5,00	15,70	12	0	300	2000	6000	14
Aromáticos, ml / 100 ml	29,0	25,0	29,0	25,0	0,0	25,0	27,0	26,3
Índice de Cetano	42,0	51,0	46,0	48,0	55,0	50,0	40,0	49,3
Biocombustible, ml / 100 ml	0,0	0,0	0,0	100,0	100,0	0,0	0,0	1,9
Microcarbón Residual, g / 100 g	0,01	0,01	0,01	0,01	0,00	0,01	0,02	0,01
Gravedad API	41,3	31,5	31,3	42,0	31,0	36,4	33,5	31,6
Viscosidad a 40°C, mm2/s	1,4	5,7	4,2	3,325	6,3	3	2	5,1
T 95% vol recobrado, °C	260,0	382,4	344,4	340,0	340,8	415,0	196,0	373,8
Punto de Inflamación, °C	35,0	122,2	75,0	67,8	130,0	65,6	40,0	93,0
Flujo, barriles/hora (bls/hr)	0,0	2200,0	1100,0	64,0	0,0	0,0	0,0	3364
Volumen, Bls	0	52800	26400	1536	0	900	0	91636

Esto se comparó con el resultado final del diésel producto analizado en laboratorio luego de la preparación, los cuales aparecen reflejado en la Tabla 38 que muestra los registros para la fecha analizada.

Los resultados de la matriz de mezcla como los obtenidos por laboratorio muestran que la especificación objetivo en destilación al 95% de recobrado es muy similar como se aprecia por laboratorio el resultado fue de 373,4 ° C y por la herramienta de Excel de 373,8 ° C. Esta preparación se estableció en el orden de 80200 Bls/día aproximadamente, reflejando un ingreso económico de 52800 dólares/día aproximadamente.

Tabla 39. Resultados de laboratorio de la preparación evaluada

FECHA MUESTRA	ESTUDIO	ANALISIS	METODO	RESULTADO
25/01/2016 7:27:24 a, m,	CASA DE BOMBAS 9	PTO INICIAL DE EBULLICION	ASTM D 86	193,8 °C
25/01/2016 7:27:24 a, m,	CASA DE BOMBAS 9	5% vol, RECOBRADO	ASTM D 86	226,8 °C
25/01/2016 7:27:24 a, m,	CASA DE BOMBAS 9	10% vol, RECOBRADO	ASTM D 86	238,2 °C
25/01/2016 7:27:24 a, m,	CASA DE BOMBAS 9	50% vol, RECOBRADO,	ASTM D 86	291,8 °C
25/01/2016 7:27:24 a, m,	CASA DE BOMBAS 9	90% vol, RECOBRADO,	ASTM D 86	352,5 °C
25/01/2016 7:27:24 a, m,	CASA DE BOMBAS 9	95% vol, RECOBRADO	ASTM D 86	373,4 °C
25/01/2016 7:27:24 a, m,	CASA DE BOMBAS 9	PTO FINAL DE EBULLICION	ASTM D 86	381,7 °C
25/01/2016 7:27:24 a, m,	CASA DE BOMBAS 9	AZUFRE EN PPM	ASTM D 2622 AZUFRE POR RAYOS X	14,7 mg/kg
25/01/2016 7:27:24 a, m,	CASA DE BOMBAS 9	CONTENIDO DE BIOCOMBUSTIBLES	EN 14078 METODO PARA CONTENIDO BIOCOMBUSTIBLE	2,17 % vol
25/01/2016 7:27:24 a, m,	CASA DE BOMBAS 9	DENSIDAD A 60° F	ASTM D 4737 INDICE CETANO CALCULADO	,8581013349514562 N/A
25/01/2016 7:27:24 a, m,	CASA DE BOMBAS 9	DENSIDAD A 60° F	ASTM D 4052-11 DENSIDAD	858,00 kg/m3
25/01/2016 7:27:24 a, m,	CASA DE BOMBAS 9	GRAVEDAD API	ASTM D 4052-11 DENSIDAD-DENSI, DIGITAL	33,3 Grados API
25/01/2016 7:27:24 a, m,	CASA DE BOMBAS 9	GRAVEDAD API,	ASTM D 4737 INDICE CETANO CALCULADO	33,3 Grados API
25/01/2016 7:27:24 a, m,	CASA DE BOMBAS 9	INDICE DE CETANO	ASTM D 4737 INDICE CETANO CALCULADO	50 N/A

Basado en los resultados anteriores se buscó a través de la definición de un valor objetivo que la preparación se optimizara con el aprovechamiento de los componentes y lograr que los flujos fueran los económicamente más viables para la preparación. Para ello se analizaron las corrientes analizando el valor objetivo de 35 ppm de azufre para el diésel B₂E, ello implicó la utilización de otras corrientes como acpm de UNIBON, Virginoil y jet hidrotratado, como lo muestra la Tabla 39. Esta evaluación muestra que con los parámetros obtenidos en laboratorio no es viable la preparación en las especificaciones objetivo ya que el

sistema requiere un volumen mucho mayor de jet hidrotratado para poder corregir la dosificación de otras corrientes que podrían incrementar el contenido de azufre esa sobredosificación es económicamente inviable por las restricciones propias del sistema.

Tabla 40. Resultados de la preparación evaluados con el modelo de optimización.

PARÁMETRO	JET HDT	ACPM HDT	ACEM	Biodiesel	Virginoil	Unibón	TOPPING	DIESEL REGULAR
Azufre, ppm	5,00	15,70	12	0	300	2000	6000	35
Aromáticos, ml / 100 ml	29,0	25,0	29,0	25,0	0,0	25,0	27,0	26,8
Índice de Cetano	42,0	51,0	46,0	48,0	55,0	50,0	40,0	47,7
Biocombustible, ml / 100 ml	0,0	0,0	0,0	100,0	100,0	0,0	0,0	2,0
Micro carbón Residual, g / 100 g	0,01	0,01	0,01	0,01	0,00	0,01	0,02	0,01
Gravedad API	41,3	31,5	31,3	42,0	31,0	36,4	33,5	33,3
Viscosidad a 40°C, mm ² /s	1,4	5,7	4,2	3,325	6,3	3	2	3,7
T 95% vol recobrado, °C	260,0	382,4	344,4	340,0	340,8	415,0	196,0	366,5
PFE, °C	266,7	383,7	364,1	380,5	353,0	351,5	203,1	391,5
Punto de Inflamación, °C	35,0	122,2	75,0	67,8	130,0	65,6	40,0	62,5
Flujo, barriles/hora (bls/hr)	862,1	2100,0	1500,0	42,0	50,0	45,9	0,0	4600
Volumen, Bls	20690	50400	36000	1008	1200	900	0	120198

Luego se evaluó el incremento de la destilación para satisfacer las especificaciones requeridas, obteniendo que la mínima destilación proveniente del acpm hidrotratado debiera ser 390 °C, lo anterior refleja la oportunidad de incrementar la destilación en las unidades de carga de crudo, eso permite un mayor aprovechamiento en productos valiosos del proceso de refinación. Tal como se aprecia en la Tabla 40. El aprovechamiento de otras corrientes en la preparación de diésel B₂E que permiten incrementar el contenido de azufre y la destilación requiere un incremento en los flujos de preparación a 3776 Bls/h o su equivalente a 90600 bpd

Tabla 41. Resultados de la matriz de optimización para destilación en 380 ° C

PARÁMETRO	JET HDT	HDT	ACEM	Biodiesel	Virginoil	Unibon	TOPPING	DIESEL REGULAR
Azufre, ppm	5,00	15,70	12	0	300	2000	6000	35
Aromáticos, ml / 100 ml	29,0	25,0	29,0	25,0	0,0	25,0	27,0	26,4
Índice de Cetano	42,0	51,0	46,0	48,0	55,0	50,0	40,0	48,9
Biocombustible, ml / 100 ml	0,0	0,0	0,0	100,0	100,0	0,0	0,0	2,0
Micro carbón Residual, g / 100 g	0,01	0,01	0,01	0,01	0,00	0,01	0,02	0,01
Gravedad API	41,3	31,5	31,3	42,0	31,0	36,4	33,5	31,7
Viscosidad a 40°C, mm2/s	1,4	5,7	4,2	3,325	6,3	3	2	4,8
T 95% vol recobrado, °C	260,0	390,0	344,4	340,0	340,8	415,0	196,0	378,0
PFE, °C	266,7	383,7	364,1	380,5	353,0	351,5	203,1	393,5
Punto de Inflamación, °C	35,0	122,2	75,0	67,8	130,0	65,6	40,0	84,9
Flujo, barriles/hora (bls/hr)	64,4	2100,0	1500,0	42,0	33,5	36,4	0,0	3776
Volumen, Bls	1544	50400	36000	1008	805	873	0	90630

Escenario 2 para preparaciones de diésel con destilación al 95% de recobrado en 370° C

Para esta evaluación se contempló las características propias de las corrientes utilizadas en la preparación de diésel B₂E y los flujos y composiciones propios en una mezcla real de diésel, teniendo en cuenta los análisis del laboratorio industrial (Tabla 41).

Tabla 42. Calculo de destilación con valores de T-95 en 370 optimizado

PARÁMETRO	JET HDT	HDT	ACEM	Biodiesel	Virginoil	Unibon	Diésel regular
Azufre, ppm	5,00	26,00	12	0	300	2000	33
Aromáticos, ml / 100 ml	29,0	25,0	29,0	25,0	0,0	25,0	26,4
Índice de Cetano	42,0	51,0	46,0	48,0	55,0	50,0	48,8
Biocombustible, ml / 100 ml	0,0	0,0	0,0	100,0	100,0	0,0	2,4
Micro carbón Residual, g / 100 g	0,01	0,01	0,01	0,01	0,00	0,01	0,01
Gravedad API	41,3	31,5	31,3	42,0	31,0	36,4	31,8

PARÁMETRO	JET HDT	HDT	ACEM	Biodiesel	Virginoil	Unibon	Diésel regular
Viscosidad a 40°C, mm ² /s	1,4	5,7	4,2	3,325	6,3	3	4,8
T 95% vol recobrado, °C	320,0	380,0	342,0	340,0	340,8	415,0	368,8
Punto de Inflamación, °C	35,0	122,2	75,0	67,8	130,0	65,6	83,0
Flujo, barriles/hora (bls/hr)	100,0	2100,0	1500,0	42,0	50,0	20,0	3812
Volumen, Bls	2400	50400	36000	1008	1200	900	91488

Se realizó pruebas adicionales con datos de diferentes fechas en el primer semestre de 2016. Una de esas evaluaciones reporta los siguientes resultados de flujo y composición analizados a través de la herramienta de Excel los cuales están especificados en el registro de la Tabla 42.

Tabla 43. Evaluación de los resultados de preparación sin optimizar

Parámetro	Remanente	Jet HDT	ACPM HDT	Acem	Biodiesel	Virginoil	Unibon	Topping	Diésel regular
Azufre, ppm	70	5,00	25,00	6	0	300	2000	6000	23
Aromáticos, ml / 100 ml	23,0	29,0	25,0	29,0	25,0	0,0	25,0	27,0	26,0
Índice de Cetano	49,0	42,0	51,0	46,0	48,0	55,0	50,0	40,0	49,2
Biocombustible, ml / 100 ml	1,6	0,0	0,0	0,0	100,0	0,0	0,0	0,0	1,9
Micro carbón Residual, g / 100 g	0,02	0,01	0,01	0,01	0,01	0,00	0,01	0,02	0,01
Gravedad API	33,4	41,3	31,5	31,3	42,0	31,0	36,4	33,5	31,6
Viscosidad a 40°C, mm ² /s	3,95	1,4	5,7	4,2	3,325	6,3	3	2	5,0
T 95% vol recobrado, °C	370,0	320,0	378,8	350,6	340,0	340,8	415,0	196,0	370,2
PFE, °C	379,0	266,7	383,7	364,1	350,5	353,0	351,5	203,1	377,1
Punto de Inflamación, °C	77,8	35,0	122,2	75,0	67,8	130,0	65,6	40,0	91,3
Porcentaje v/v con remanente	0,0	0,0	59,6	36,6	1,9	1,9	0,0	0,0	100,0
Porcentaje v/v sin remanente	NA	0,0	59,0	36,2	1,9	1,9	1,1	0,0	100,0
Flujo, barriles/hora (bls/hr)	0	0,0	2100	1288	66,4	66,3	0,0	0,0	3521

Los anteriores resultados fueron comparados con los resultados de laboratorio realizados en la misma fecha registrando valores significativamente muy similares a los calculados en la matriz donde el análisis de azufre por la herramienta fue de

23 ppm vs 22 encontrados por laboratorio. Otro de los análisis que fue la destilación al 95% de volumen recobrado reporta en la herramienta de 370.2 ° C vs 370.6 ° C por laboratorio. (Tabla 43)

Tabla 44. Resultados de laboratorio de acuerdo a flujos de preparación.

Fecha	Muestra	Análisis	Método	Valor	Uom
16/04/2016 7:00	DIESEL REGULAR B2	AZUFRE EN PPM	ASTM D 2622 AZUFRE	22	mg/kg
16/04/2016 7:00	DIESEL REGULAR B2	PTO INICIAL DE EBULLICION	ASTM D 86 DESTILACION PRODUCTOS DEL P.	183	°C
16/04/2016 7:00	DIESEL REGULAR B2	95% vol. RECOBRADO	ASTM D 86 DESTILACION PRODUCTOS DEL P.	370.6	°C
16/04/2016 7:00	DIESEL REGULAR B2	PTO FINAL DE EBULLICION	ASTM D 86 DESTILACION PRODUCTOS DEL P.	378.3	°C

Parte del estudio de optimización permitió encontrar datos que reflejen una mejor configuración de los flujos a partir de las composiciones de las muestras caracterizadas a los componentes, esto permitió definir para la mezcla anteriormente descrita la siguiente definición de flujos con las propiedades analizadas para dicha fecha (Tabla 43).

Los resultados económicos de esta preparación con los flujos y estimación de los componentes reflejan ingresos brutos día de 250000 dólares y una ganancia estimada de 67000 dólares aproximadamente. Esto permite evidenciar mejoras significativas con la implementación de herramientas de optimización de las preparaciones, donde los resultados del diésel final cuentan con valores estimados más acordes a la proyección del negocio (Tabla 44).

Tabla 45. Resultados de nueva validación de optimización.

PARÁMETRO	JET HDT	HDT	ACEM	Biodiesel	Virginoil	Unibon	DIESEL REGULAR
Azufre, ppm	5,00	26,00	12	0	300	700	30
Aromáticos, ml / 100 ml	29,0	25,0	29,0	25,0	0,0	25,0	26,4
Índice de Cetano	42,0	51,0	46,0	48,0	55,0	50,0	48,6
Biocombustible, ml / 100 ml	0,0	0,0	0,0	100,0	0,0	0,0	1,8
Micro carbón Residual, g / 100 g	0,01	0,01	0,01	0,01	0,00	0,01	0,01
Gravedad API	41,3	31,5	31,3	42,0	31,0	36,4	32,2
Viscosidad a 40°C, mm2/s	1,4	5,7	4,2	3,325	6,3	3	4,5
T 95% vol recobrado, °C	320,0	378,8	350,6	340,0	340,8	415,0	369,2
PFE, °C	266,7	383,7	359,1	350,5	353,0	351,5	375,6
Punto de Inflamación, °C	35,0	122,2	75,0	67,8	130,0	65,6	76,6
Porcentaje v/v CON REMANENTE	5,8	52,5	37,5	1,8	1,2	1,1	100,0
Porcentaje v/v SIN REMANENTE	5,8	52,5	37,5	1,8	1,2	1,1	100,0
Flujo, barriles/hora (bls/hr)	232,8	2100,0	1500,0	72,0	50,0	45,2	4000
Volumen, Bls	5587	50400	36000	1728	1200	1085	96000
VALOR, US\$/Bls	60,0	55,0	60,2	147,0	40,0	55,8	59,0
VALOR TOTAL, M US\$	0,34	2,77	2,17	0,25	0,05	0,06	6,26

5.5. EVALUACION ADICIONAL AL MODELO DE OPTIMIZACION

Con el interés de obtener resultados más concretos dentro de la evaluación económica, se realizaron cuatro evaluaciones adicionales teniendo en cuenta los resultados de laboratorio de los componentes. A continuación, se muestra los resultados obtenidos durante las corridas de evaluación y sus correspondientes soportes de mezcla. En estos escenarios, se evaluaron los componentes tradicionales teniendo en cuenta las características propias de los mismos y el producto final. Estos valores fueron confrontados con los resultados de laboratorio para luego realizar una evaluación con la utilización de la herramienta de optimización diseñada para la mezcla de diésel.

En la primera evaluación, la Tabla 45 muestra los flujos de preparación estimados para un día de mezcla, su correspondiente potencial económico al igual que los resultados tanto por mezcla como por laboratorio de dicha preparación.

Tabla 46. Resultados de preparación inicial

Resultados de la preparación normal								
					Resultados por mezcla		Resultados por laboratorio	
Flujo preparación	Flujo. preparación	Valor	Costos de Materia prima	diferencial	Azufre	Destilación	Azufre	Destilación
Bls/hr	Bls/día	U\$	U\$	U\$	ppm	T-95% recobrado	ppm	T-95% recobrado
3470	83280	5200000	4912003	287996	17	372,8	27	375

Como se puede apreciar el parámetro de destilación se encuentra fuera del rango permitido, lo cual hace necesario tomar acciones para llevar a control de una mezcla que satisfaga las características exigidas. Basado en lo anterior se utilizó para esta primera corrida la evaluación de los componentes con la aplicación de la herramienta de optimización. La Tabla 46 muestra los resultados de este proceso y el aporte económico que implica para la organización aprovechar la preparación bajo parámetros más ajustados a los límites de calidad.

Tabla 47. Primera corrida de optimización.

Resultados aplicando la optimización							
					calidad optimizada		Ganancia adicional
Flujo preparación	Flujo. preparación	Valor	Costos de Materia prima	diferencial	Azufre	Destilación	U\$ /día
Bls/hr	Bls/día	U\$	U\$	U\$	ppm	T-95% recobrado	
4000	96000	6000000	5642607,151	357393,843	30	370	69397,04293

De la primera corrida de optimización se aprecia que se cumple con especificaciones más acordes a la norma y que arroja un potencial económico adicional de aproximadamente 69000 dólares diarios.

Una segunda evaluación se llevó a cabo con resultados de laboratorio para otra serie de preparación tal como se aprecia en la Tabla 47. Estos valores se analizaron de igual forma en el modelo de optimización, los cuales se observan en la Tabla 48. Allí se aprecia que los valores obtenidos por la herramienta ofrecen un beneficio tanto económico como de calidad mucho mejor que los efectuados en la Tabla 47. Arrojando un potencial adicional como incremento económico de 107000 dólares/día entre los resultados obtenidos en la Tabla 47 y la Tabla 48.

Tabla 48. Segunda corrida de evaluación.

Resultados de la preparación normal								
					Resultados por mezcla		Resultados por laboratorio	
Flujo preparación	Flujo. preparación	Valor	Costos de Materia prima	diferencial	Azufre	Destilación	Azufre	Destilación
Bls/hr	Bls/día	U\$	U\$	U\$	ppm	T-95% recobrado	ppm	T-95% recobrado
3168	76032	4752000	4490371,2	261628,8	19	372,9	20,4	370,7

Tabla 49. Segunda corrida para validación de optimización

Resultados aplicando la optimización							
					Resultados optimización		Ganancia adicional
Flujo preparación	Flujo. preparación	Valor	Costos de materia prima	diferencial	Azufre	Destilación	
Bls/hr	Bls/día	U\$	U\$	U\$	ppm	T-95% recobrado	U\$ /día
4000	96000	6000001	5630617	369384	30	370	107755

Posteriormente se realizó una corrida con otras características de los componentes (los cuales se aprecian en el anexo F tabla 55). La Tabla 49 muestra en esta preparación que las especificaciones de calidad en destilación se encuentran fuera del rango y los resultados de azufre distan 10 ppm entre

laboratorio y la mezcla y se confirman por los análisis obtenidos por el laboratorio industrial.

Tabla 50. Tercera Corrida de preparación.

Resultados de la preparación normal								
					Resultados por mezcla		Resultados por laboratorio	
Flujo preparación	Flujo. preparación	Valor	Costos de materia prima	diferencial	Azufre	Destilación	Azufre	Destilación
Bls/hr	Bls/día	U\$	U\$	U\$ /día	ppm	T-95% recobrado	ppm	T-95% recobrado
3470	83280	5200000	4912003	287996	17	372,8	27	375

Nuevamente se ratifica que la herramienta de optimización ofrece mejores resultados (Tabla 50) que los encontrados en la anterior preparación. Los valores obtenidos reflejan destilación en el máximo rango y el azufre en valores económicamente más viables, permitiendo la adición de nuevos componentes (anexo F Tabla 56).

Tabla 51. Tercera Corrida de optimización.

Resultados aplicando la optimización							
					Resultados optimización		Ganancia adicional
Flujo preparación	Flujo. preparación	Valor	Costos de materia prima	diferencial	Azufre	Destilación	U\$ /día
Bls/hr	Bls/día	U\$	U\$	U\$	ppm	T-95% recobrado	
4500	108000	6750000,958	6294222,043	455778,9155	30	370	167782,9155

Una última corrida se desarrolló para analizar las preparaciones realizadas en el blending, en esta última se aprecia que la destilación muestra valores aceptables con una temperatura el 95% de recobrado en 367,9 por matriz y analizada por laboratorio en 366,5, de igual forma se aprecia que el resultado de azufre dista 7

ppm entre la mezcla y el laboratorio. Esta preparación (Tabla 51) ofrece un potencial económico de 356.000 dólares/día aproximadamente.

Tabla 52. Cuarta Corrida de preparación

Resultados de la preparación normal								
					Resultados por mezcla		Resultados por laboratorio	
Flujo preparación	Flujo. preparación	Valor	Costos de materia prima	diferencial	Azufre	Destilación	Azufre	Destilación
Bls/hr	Bls/día	U\$	U\$	U\$	ppm	T-95% recobrado	ppm	T-95% recobrado
3913	93912	5869500	5513040	356460	13	367,9	20	366,5

En esta última evaluación (Tabla 52) queda expresada la importancia de realizar la preparación de diésel con la ayuda de herramientas que permitan el aprovechamiento de los componentes de forma acorde a las necesidades de la organización, se ratifica las potenciales ganancias adicionales y se sustenta en el anexo F Tabla 57.

Tabla 53. Cuarta corrida de optimización.

Resultados aplicando la optimización							
					Resultados optimización		Ganancia adicional
Flujo preparación	Flujo. Preparación	Valor	Costos de Materia prima	diferencial	Azufre	Destilación	
Bls/hr	Bls/día	U\$	U\$	U\$ /día	ppm	T-95% recobrado	U\$ /día
4500	108000	6750000	6302352	447648	30	370	91188

En esta corrida se aprecia un potencial beneficio económico luego de la optimización de 91000 dólares diarios. Los resultados de las evaluaciones

realizadas en estas preparaciones se encuentran consignados en el anexo F entre las tablas 55 y 62 de este documento.

6. IMPACTO DE LOS RESULTADOS DEL PRESENTE TRABAJO

Luego de los resultados obtenidos en el presente trabajo, fue posible aclarar que, con un manejo más adecuado de las condiciones operativas de las unidades de destilación de crudo, y un proceso de hidrotratamiento de diésel más acorde a las necesidades operativas de la organización, con lo cual es posible obtener resultados que beneficien los intereses del grupo empresarial. Esto se ve reflejado con la ayuda que brinda la red neuronal y la simulación realizada al área de reacción, de forma tal que permita crear estrategias para una toma de decisiones más oportuna en el proceso de hidrotratamiento, reduciendo el tiempo para actuar y anticiparse ante cualquier perturbación del proceso.

Lo anterior provee de mayores y mejores herramientas para evitar consumos inadecuados de los insumos como catalizador, energía, vapor, hidrógeno, entre otros. De igual forma se puede extender el tiempo de vida del catalizador, permite además al supervisor de hidrotratamiento contar con una ayuda para validar las condiciones operacionales en el área de reacción y dar un aprovechamiento más adecuado al proceso y por ende económicamente más benéfico para los ingresos de la refinería. Adicionalmente con la definición de parámetros más acordes desde el inicio de la cadena de tratamiento de crudos, la refinación del mismo y el hidrotratamiento de acpm, es posible mejorar los parámetros de calidad definidos para las preparaciones de diésel B₂E en el área de blending de productos, permitiendo al supervisor del área de blending aprovechar estas herramientas para anticiparse a los posibles cambios por variaciones en las especificaciones de calidad de los componentes utilizados. Con lo anterior, es posible asegurar el cumplimiento de la entrega del producto en las especificaciones establecidas a los diferentes clientes, evitar afectación a los procesos por disminución en la carga general de la refinería, hidrotratamiento y demás áreas relacionadas con el

proceso de blending de diésel, asegurar el recibo de componentes externos y que son de importancia significativa en la preparación y calidad de los productos.

Cada uno de los beneficios se valora con un potencial económico de la siguiente manera:

Por un mayor tiempo de vida de catalizador y extensión de la corrida en la unidad de hidrotratamiento de diésel, se obtienen un beneficio económico de 330000 dólares por año, extendiéndose en 4 meses el tiempo de operación de la unidad. Por preparaciones de diésel con los parámetros de calidad de temperatura al 95% de recobrado en el rango de 369 ° C y 370° C en 3.1 millones de dólares por año. Preparación de diésel en el parámetro de contenido de azufre entre 35 y 38 ppm 2.25 millones de dólares por año.

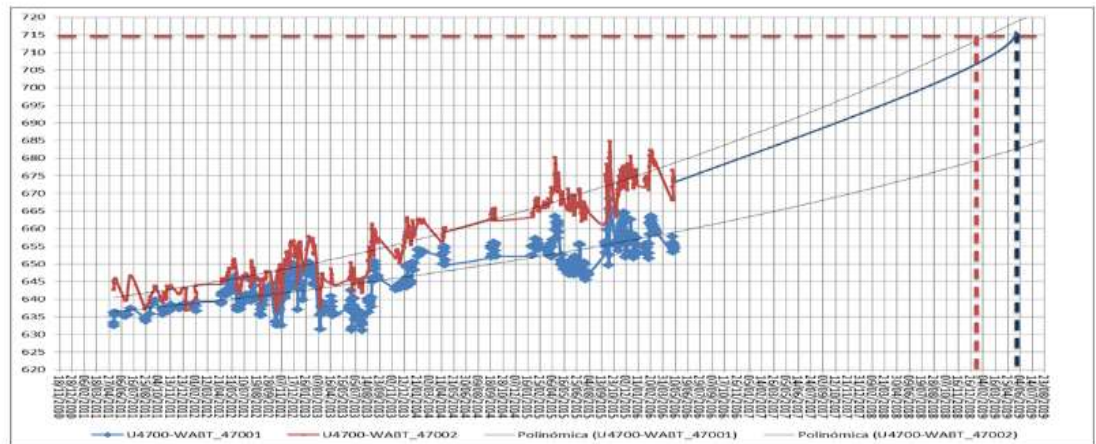
Adicional a los ingresos por la venta de diésel como por la parte de HDT, se logra reducción en el tiempo para la toma de decisiones, ayuda para evitar reproceso de diésel preparado, ayuda para determinar las condiciones operacionales en el reactor.

6.1. IMPACTO EN HDT

De acuerdo a los resultados obtenidos en la preparación de diésel y el proceso de hidrotratamiento se analiza que, con valores adecuados de severidad en la unidad, es posible aprovechar con un mayor tiempo de vida los insumos para el proceso de hidrotratamiento. Es importante mencionar que el costo del catalizador el cual tiene una reposición cada 4 años es del orden aproximado de 10 millones de dólares. Las comprobaciones realizadas con la red neuronal, permiten establecer que para un acpm hidrotratado con valores de 50 ppm a la salida de HDT es

posible alargar el tiempo de vida del catalizador en 4 meses tal como se evidencia en la figura 33.

Figura 32. Proyección de operación de la unidad de hidrot ratamiento



Los resultados obtenidos a la salida de la planta permiten una preparación en el diésel B₂E en el rango de 30 a 37 ppm de azufre (figura 34) y destilaciones al 95% de recobrado con una mejor recuperación de producto (figura 35). Estas condiciones permitirán tener preparaciones más estables, reflejándose en un ingreso económico potencial del orden de los 2 millones de dólares por concepto de disminución de diésel importado para satisfacer las necesidades del país.

Figura 33. Tendencia de azufre (ppm) en preparación de diésel



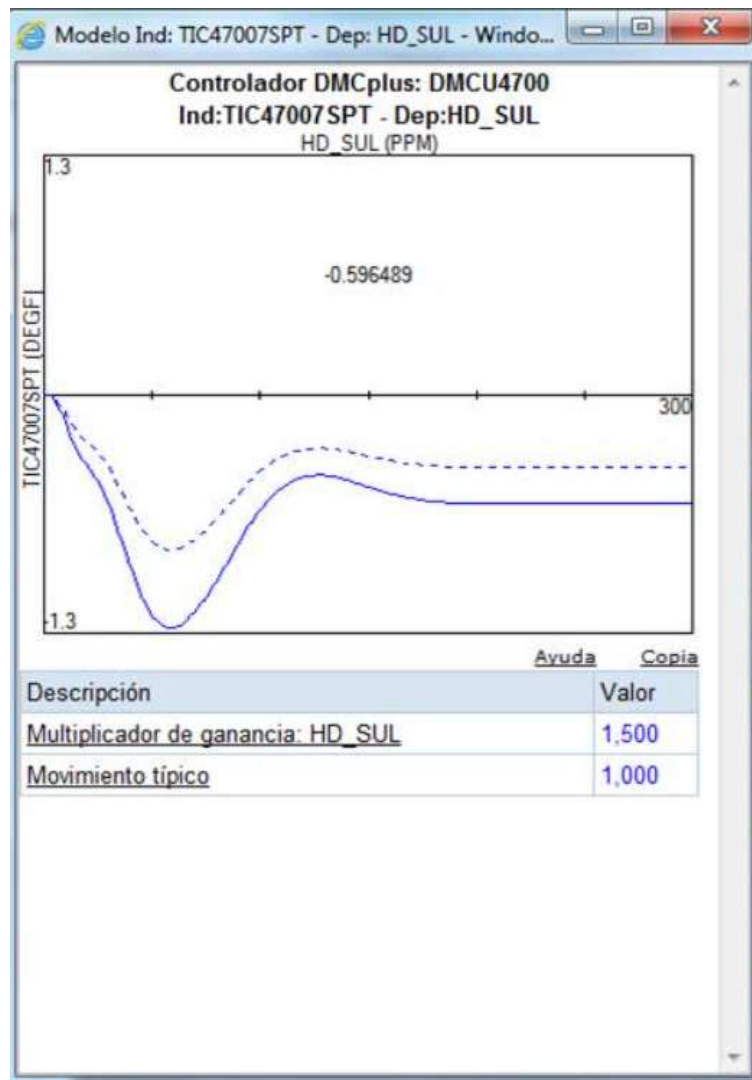


Figura 34. Tendencia de destilación de preparaciones de diésel final



Adicionalmente, la aplicación de la red permitiría realizar ajustes significativos en la unidad de hidrotreatmento, anticipando el tiempo de respuesta de los resultados, siendo este un respaldo para el supervisor durante el control de proceso. (figura 36).

Figura 35. Tendencia de proceso de ajuste de variable de azufre del controlador DMC PLUS unidad de hidrotreatmento



Fuente Ecopetrol.

7. CONCLUSIONES

- Un Incremento en la carga del crudo LCT a las unidades de destilación de la refinería conduce a una disminución en el rendimiento y en el contenido de azufre en el acpm a procesar en la unidad de hidrotratamiento.
- La simulación en HYSYS desarrollada en el presente trabajo, que envuelve las unidades de destilación, la unidad de HDT y el proceso de blending de acpm reproduce los resultados consignados en los datos históricos de proceso, con lo cual esta simulación pasa a ser una herramienta importante para el análisis de casos operativos y para la planeación de la operación.
- Las redes neuronales desarrolladas, permite predecir el comportamiento de la unidad de hidrotratamiento de diésel y sumado a la optimización por simulación, resultan ser complementos para alcanzar el mayor beneficio económico.
- El modelo de optimización codificado en Excel al ser mejorado, conduce a la definición de preparaciones de diésel con características comerciales adecuadas y con un margen de refinación que puede beneficiar a la GRB y por ende a la economía de la compañía.

8. RECOMENDACIONES.

- Aplicar los resultados generados con el modelo de optimización para lograr un aumento en las ganancias por producción de diésel comercial B2E.
- Realizar validaciones adicionales a las redes neuronales para hidrotreatmento de acpm contemplando la inclusión de otras variables de proceso y especificaciones de calidad propias del acpm.
- Implementar modelos de simulación tanto de optimización de mezclas de preparación de combustibles, hidrotreatmento de diésel para integrar los procesos y reducir en un 80% los reprocesos y afectaciones de calidad tanto por defecto como por sobre-entrega, para alcanzar mayor beneficio por margen de refinación y por cumplimiento de ventas de producto.
- Diseñar una red neuronal que contemple todas las condiciones de proceso desde la unidad de refinación de crudos hasta el área de Blending de diésel con la aplicación de lógica difusa.

REFERENCIAS BIBLIOGRÁFICAS

- [1] A. Serna, D. Peña, R. González y H. Quiroga, « Evaluación del efecto corrosivo de los crudos,» *Revista ION*, nº 23, pp. 99-110, 2010.
- [2] J. H. Arango, «Calidad de los combustibles en Colombia,» *revista de ingeniería. Universidad de los Andes.*, vol. 29, pp. 100-108, 2009.
- [3] Ministerio de Minas y Energía. [En línea]. Available: <http://www.minminas.gov.co/documents/10180//23517//26101-92963.pdf>. [Último acceso: 5 abril 2016.].
- [4] E. Gomez, *Filosofía de operación del Blending de Diesel de la Gerencia Refinería Barrancabermeja*, Barrancabermeja, Santander, 2010.
- [5] V. Miguel y L. Passini, «Hidrotratamiento de nafta y diesel en refinería de Bahía Blanca.,» *Petrotecnia*, pp. 72-79., Abril 2010.
- [6] ECOPETROL, *Manual de Procesos de la Unidad de Procesos de Hidrotratamiento. Gerencia Complejo Barrancabermeja.*, Barrancabermeja, 2009.
- [7] E. Verruschi, «Optimización de La distribución de catalizadores en hidrotratamiento de destilados medios,» 2008. [En línea]. Available: <http://oa.upm.es/1192>. [Último acceso: 10 Agosto 2015].
- [8] E. Narimani y J. Alaei, «Simulation of hydrodesulfurization unit for natural gas condensate with high sulfur content,» *Applied Petrochemical Research*, vol. 6, pp. 25-34, 1 3 2016.
- [9] S. Shokri, M. Taghi, S. Mahdi, A. Marvast y S. Narasimhan, «Improvement of the prediction performance of a soft sensor model based on support vector regression for production of ultra-low sulfur diesel,» *Pet. Sci.*, vol. 12, pp. 177-188, 2015.

- [10] M. Álvarez, L. Hoyos y L. Zambrano, « Modelado del proceso de Hidrotratamiento de diésel,» *Revistas.uis.edu.co* , vol. 25, pp. 7-14, 2012.
- [11] H. Singh, « Performance Characteristics of Biodiesel Blend in CI Engine using Artificial Neural Network (Karanja Oil),» *NIET Journal of Engineering & Technology*, vol. 1, pp. 46-53 , 2013.
- [12] I. Lukec, K. Sertić y L. Darko, «Prediction of sulphur content in the industrial hydrotreatment process.,» *Journal FUEL PROCESSING TECHNOLOGY*, vol. 89, p. 292 – 300 , 2008.
- [13] E. Arce y J. Paz, «Artificial neural network modeling techniques applied to the hydrodesulfurization process,» *Mathematical and Computer Modelling*, vol. 49, pp. 207-214, 2009.
- [14] R. Santana, P. Doa, M. Santikunaporna, W. Alvarez, J. Taylor, E. Sughrieb y D. Resascoa, «Evaluation of different reaction strategies for the improvement of cetane number in diesel fuels.,» *Journal FUEL*, vol. 85, p. 643–656., 2006.
- [15] J. Kumar y A. Bansal, « Application of artificial neural network to predict properties of diesel –biodiesel blends.,» *Journal of science, engineering and technology*, vol. 6, pp. 98 - 103, 2010.
- [16] Y. Sánchez, R. Piloto, M. Errasti, R. Sierens y S. Verhelst, «Prediction of cetane number and ignition delay of biodiesel using Artificial Neural Networks.,» *Energy Procedia Journal*, vol. 57, p. 877 – 885, 2014.
- [17] J. Hilera y V. Martínez, *Redes Neuronales Artificiales*, México: Alfa omega, 2000.
- [18] J. Trujillano, M. Badia, L. Serviá, J. March y A. Rodríguez, «Redes neuronales artificiales en Medicina Intensiva. Ejemplo de aplicación con las variables del MPM II,» *Medicina Intensiva*, vol. 29, nº 1, pp. 13-20, 2005.
- [19] B. Martin del Brio y A. Sanz Molina, *Redes Neuronales y Sistemas Difusos*, 2da ed., Mexico: AlfaOmega, 2002.

- [20] P. ponce, *Inteligencia con aplicaciones en ingeniería*, Mexico: Alfa omega, 2010.
- [21] G. Sotolongo y M. V. Guzmán, «Aplicaciones de las redes neuronales. El caso de la bibliometría.,» *ciencias de la informacion*, vol. 32, nº 1, pp. 27-34, 2001.
- [22] A. Tech, *Hand book of processes simulation. Aspen Tech.*
- [23] J. Hair, W. Black, B. Babin y R. Anderson, *Multivariate Data Analysis*, 7th ed., Mexico: Prentice Hall, 2009..
- [24] D. Montgomery y G. Runger, *Probabilidad y estadística aplicadas a la ingeniería*, Mexico: Mc Graw-Hill. , 1996.
- [25] K. Swingler, *Applying Neural Networks, A Practical Guide*, Londres NW 1: Press Limited Oval Road , 1996.
- [26] M. Berry y G. Linoff, *Data Mining Techniques*, Nueva York: John Wiley & Sons, 1997.
- [27] J. Donnet, *Carbon black science and tecnology*, segunda ed., New York: Marcel Dekker, INC, 1993, pp. 22-62.
- [28] A. Botello, J. von Osten, G. Gold-Bouchot y C. Agraz-Hernández, *Golfo de México contaminaciones e impacto ambiental: Diagnostico y tendencias*, 2 ed., Campeche, 2005, pp. 264-268.
- [29] Z. Lazic, *Diseño de experimentos en ingeniería química*, Weinheim: WILEY-VCH Verlag GmbH & Co, 2004, pp. 63-122.
- [30] J. C. Arias, *Propuesta de un analizador virtual (soft-sensor) para la prediccion del punto final de ebullicion del jet y t95 del acpm de la unidad de procesamiento de crudo u150 de la gerencia refineria de Barrancabermeja*, ECOPETROL S.A., Bucaramanga, 2016.
- [31] E. Verruschi, J. Padron, T. Moreno, H. Lara y W. Ángulo, «Cómo planificar óptimamente la cadena de suministros de una refinería de petróleo,» *Universidad, ciencia y tecnologia*, vol. 13, nº 53, p. 340, 2009.

- [32] A. Ramos, P. Sanchez, J. Ferrer, J. Barquin y P. Linares, «Modelos matemáticos de optimización,» Septiembre 2010. [En línea]. Available: https://www.gams.com/docs/contributed/modelado_en_gams.pdf. [Último acceso: 15 Julio 2016].

BIBLIOGRAFÍA

ÁLVAREZ M., HOYOS L. y ZAMBRANO L., «Modelado del proceso de Hidrotratamiento de diésel,» *Revistas.uis.edu.co*, vol. 25, pp. 7-14, 2012.

ARANGO J., «Calidad de los combustibles en Colombia,» *revista de ingeniería. Universidad de los Andes.*, vol. 29, pp. 100-108, 2009.

ARCE E. y PAZ J., «Artificial neural network modeling techniques applied to the hydrodesulfurization process,» *Mathematical and Computer Modelling*, vol. 49, pp. 207-214, 2009.

ARIAS J., Propuesta de un analizador virtual (Soft-Sensor) para la predicción del punto final de ebullición del jet y T95 del ACPM de la unidad de procesamiento de crudo U150 de la gerencia refinería de Barrancabermeja, *ECOPETROL S.A.*, Bucaramanga, 2016.

ASPENTECH, *Hand book of processes simulation*. Aspen Tech.

BERRY M. y LINOFF G., *Data Mining Techniques*, Nueva York: John Wiley & Sons, 1997.

BOTELLO A., VON OSTEN J., GOLD-BOUCHOT G. y AGRAZ-HERNÁNDEZ C., *Golfo de México contaminaciones e impacto ambiental: Diagnostico y tendencias*, 2 ed., Campeche, 2005, pp. 264-268.

DONNET J., *Carbon black science and technology*, segunda ed., New York: Marcel Dekker, INC, 1993, pp. 22-62.

ECOPETROL, Manual de Procesos de la Unidad de Procesos de Hidrotratamiento. Gerencia Complejo Barrancabermeja., Barrancabermeja, 2009.

GOMEZ, E, Filosofía de operación del Blending de Diesel de la Gerencia Refinería Barrancabermeja, Barrancabermeja, Santander, 2010.

HAIR J., BLACK W., BABIN B. y ANDERSON R., Multivariate Data Analysis, 7th ed., Mexico: Prentice Hall, 2009.

HILERA J. y MARTÍNEZ V., Redes Neuronales Artificiales, México: Alfa omega, 2000.

KUMAR J. y BANSAL A., « Application of artificial neural network to predict properties of diesel –biodiesel blends. » Journal of science, engineering and technology, vol. 6, pp. 98 - 103, 2010.

LAZIC Z., Diseño de experimentos en ingeniería química, Weinheim: WILEY-VCH Verlag GmbH & Co, 2004, pp. 63-122.

LUKEC I., SERTIĆ K. y DARKO L., «Prediction of sulphur content in the industrial hydrotreatment process., » Journal FUEL PROCESSING TECHNOLOGY, vol. 89, pp. 292 – 300, 2008.

MARTIN DEL BRIO B. y SANZ MOLINA A., Redes Neuronales y Sistemas Difusos, 2da ed., México: AlfaOmega, 2002.

MIGUEL V. y PASSINI L., «Hidrotratamiento de nafta y diésel en refinería de Bahía Blanca.,» Petrotecnia, pp. 72-79., Abril 2010.

MINISTERIO DE MINAS Y ENERGIA. [En línea]. Available: <http://www.minminas.gov.co/documents/10180//23517//26101-92963.pdf>. [Último acceso: 5 abril 2016.].

MONTGOMERY D. y RUNGER G., Probabilidad y estadística aplicadas a la ingeniería, México: Mc Graw-Hill., 1996.

NARIMANI E. y ALAEI J., «Simulation of hydrodesulfurization unit for natural gas condensate with high sulfur content, » Applied Petrochemical Research, vol. 6, pp. 25-34, 1 3 2016.

PONCE P., Inteligencia con aplicaciones en ingeniería, México: Alfa omega, 2010.

RAMOS A., SANCHEZ P., FERRER J., BARQUIN J. y LINARES P., «Modelos matemáticos de optimización,» Septiembre 2010. [En línea]. Available: https://www.gams.com/docs/contributed/modelado_en_gams.pdf. [Último acceso: 15 Julio 2016].

SÁNCHEZ Y., PILOTO R., ERRASTI M., SIERENS R. y VERHELST S., «Prediction of cetane number and ignition delay of biodiesel using Artificial Neural Networks.,» Energy Procedia Journal, vol. 57, p. 877 – 885, 2014.

SANTANA R., DOA P., M SANTIKUNAPORNA., ALVAREZ W., TAYLOR J., SUGHRUEB E. y RESASCOA D., «Evaluation of different reaction strategies for the improvement of cetane number in diesel fuels.,» Journal FUEL, vol. 85, p. 643–656., 2006.

SERNA A., PEÑA D., GONZÁLEZ R. y QUIROGA H., «Evaluación del efecto corrosivo de los crudos,» Revista ION, nº 23, pp. 99-110, 2010.

SHOKRI S., TAGHI M., MAHDI S., MARVAST A. y NARASIMHAN S., «Improvement of the prediction performance of a soft sensor model based on support vector regression for production of ultra-low sulfur diesel, » Pet. Sci., vol. 12, pp. 177-188, 2015.

SINGH H., « Performance Characteristics of Biodiesel Blend in CI Engine using Artificial Neural Network (Karanja Oil), » NIET Journal of Engineering &Technology, vol. 1, pp. 46-53, 2013.

SOTOLONGO G. y GUZMÁN M., «Aplicaciones de las redes neuronales. El caso de la bibliometría.,» ciencias de la información, vol. 32, nº 1, pp. 27-34, 2001.

SWINGLER K., Applying Neural Networks, A Practical Guide, Londres NW 1: Press Limited Oval Road, 1996.

TRUJILLANO J., BADIA M., SERVIÁ L., MARCH J. y RODRÍGUEZ A., «Redes neuronales artificiales en Medicina Intensiva. Ejemplo de aplicación con las variables del MPM II,» Medicina Intensiva, vol. 29, nº 1, pp. 13-20, 2005.


VERRUSCHI E., «Optimización de La distribución de catalizadores en hidrotratamiento de destilados medios,» 2008. [En línea]. Available: <http://oa.upm.es/1192>. [Último acceso: 10 agosto 2015].

VERRUSCHI E., PADRON J., MORENO T., LARA H. y ÁNGULO W., «Cómo planificar óptimamente la cadena de suministros de una refinería de petróleo,» Universidad, ciencia y tecnología, vol. 13, nº 53, p. 340, 2009.

ANEXOS


ANEXO A. Esquemas de RNA para la predicción de variables en conjunto.

Figura 36. Esquema RNA para la predicción del flujo de ACPM hidrotratado y su contenido de azufre




Fuente: (Niño 2016).

Figura 37. Esquema RNA para la predicción del flujo de hidrógeno, cambio de temperatura y presión en la zona de reacción.



Fuente: (Niño 2016).

Figura 38. Esquema RNA para la predicción del flujo de hidrógeno y cambio de temperatura en la zona de reacción.



Fuente: (Niño 2016).

ANEXO B. Resultados RNA para las condiciones de operación H y dT.

Tabla 54. Resultados modelos de redes neuronales con las funciones de activación FA I para la predicción de H y dT.

X	R^2	MSE de entrenamiento	MSE de validación
2	0,694	7,46E-03	7,51E-03
4	0,775	5,80E-03	5,85E-03
6	0,825	4,84E-03	4,85E-03
8	0,827	4,31E-03	4,28E-03
10	0,874	3,39E-03	3,40E-03
12	0,877	3,33E-03	3,34E-03
14	0,894	2,89E-03	2,96E-03
16	0,899	2,75E-03	2,72E-03
18	0,917	2,29E-03	2,35E-03
20	0,909	2,49E-03	2,53E-03
22	0,928	1,99E-03	2,02E-03

Tabla 55. Resultados modelos de redes neuronales con las funciones de activación FA II para la predicción de H y dT.

X	R^2	MSE de entrenamiento	MSE de validación
2	0,543	1,02E-02	1,04E-02
4	0,661	8,50E-03	8,63E-03
6	0,677	8,18E-03	8,29E-03
8	0,719	7,67E-03	7,80E-03
10	0,715	7,65E-03	7,83E-03
12	0,737	7,36E-03	7,48E-03
14	0,753	7,14E-03	7,28E-03
16	0,756	7,06E-03	7,19E-03
18	0,755	7,08E-03	7,22E-03
20	0,764	6,94E-03	7,07E-03
22	0,755	7,06E-03	7,21E-03

Figura 39. Gráfica del R2 vs en número de neuronas en la capa oculta para la predicción del H y dT. Redes neuronales con función de activación FA I.




Figura 40. Gráfica del R2 vs en número de neuronas en la capa oculta para la predicción el H y dT. Redes neuronales con función de activación FA II.






Figura 41. Gráfica del MSE vs en número de neuronas en la capa oculta para la predicción del H y dT. Redes neuronales con función de activación FA I.



Fuente: (Niño 2016).


Figura 42. Gráfica del MSE vs en número de neuronas en la capa oculta para la predicción del H y dT. Redes neuronales con función de activación FA II.



Fuente: (Niño 2016).


ANEXO C. Esquemas RNA para la predicción de variables individuales.

Figura 43. Esquema RNA para la predicción del flujo del contenido de azufre en HC2.




Fuente: (Niño 2016)

Figura 44. Esquema RNA para la predicción del flujo de ACPM hidrotratado.




Fuente: (Niño 2016)

Figura 45. Esquema RNA para la predicción de la relación ACPM/hidrógeno




Fuente: (Niño 2016)

Figura 46. Esquema RNA para la predicción del flujo hidrógeno.



Fuente: (Niño 2016)

Figura 47. Esquema RNA para la predicción del cambio de temperatura en la zona de reacción.



Fuente: (Niño 2016)

ANEXO D Gráficas de dispersión de las variables del proceso de HDT.

Figura 48. Diagrama de dispersión para el flujo de ACPM (HC1)




Figura 49. Diagrama de dispersión para el punto final de ebullición (PFB).




Figura 50. Diagrama de dispersión para grados API.




Figura 51. Diagrama de dispersión para el contenido de azufre en HC1 (S1).




Figura 52. Diagrama de dispersión para el flujo de hidrógeno (H).




Figura 53. Diagrama de dispersión para la relación ACPM/hidrógeno (RR).




Figura 54. Diagrama de dispersión para la temperatura de entrada (T1).




Figura 55. Diagrama de dispersión para el cambio de temperatura en la zona de reacción (dT).




Figura 56. Diagrama de dispersión para la presión de operación en la zona de reacción (P).




Figura 57. Diagrama de dispersión para el flujo de ACPM hidrotratado (HC2).





Figura 58. Diagrama de dispersión para el contenido de azufre en HC2 (S2).



ANEXO E. Gráficas de dispersión de las variables del proceso de HDT. En la validación extra

Figura 59. Diagrama de dispersión para el punto final de ebullición (PFB) en la validación extra




Figura 60 Diagrama de dispersión para grados API en la validación extra




Figura 61. Diagrama de dispersión para el contenido de azufre en HC1 (S1) en la validación extra




Figura 62. Diagrama de dispersión para la relación ACPM/hidrógeno (RR) en la validación extra




Figura 63. Diagrama de dispersión para la temperatura de entrada (T1) en la validación extra




Figura 64. Diagrama de dispersión para la presión de operación en la zona de reacción (P) en la validación extra




Figura 65. Diagrama de dispersión para el flujo de ACPM hidrotratado (HC2) en la validación extra




Figura 66. Diagrama de dispersión para el contenido de azufre en HC2 (S2) en la validación extra





Figura 67. Diagrama de dispersión para el punto inicial de ebullición (PIB) en la validación extra



ANEXO F. Resultados de evaluación de modelo de optimización

Tabla 56. Primera corrida de preparación normal

PARÁMETRO	Jet HDT	ACPM HDT	ACEM	Biodiesel	Virginoil	Unibón	Diesel Regular
<i>Azufre, ppm</i>	5,00	26,00	5	0	300	700	17
<i>Aromáticos, ml / 100 ml</i>	29,0	25,0	29,0	25,0	0,0	25,0	26,7
<i>Índice de Cetano f (T, API)</i>	39,0	51,6	49,5	41,1	32,1	50,0	50,5
<i>Biocombustible, ml / 100 ml</i>	0,0	0,0	0,0	100,0	0,0	0,0	2,0
<i>Microcarbón Residual, g / 100 g</i>	0,01	0,01	0,01	0,01	0,00	0,01	0,01
<i>Gravedad API</i>	41,3	31,5	31,3	42,0	31,0	36,4	31,6
<i>Viscosidad a 40°C, mm²/s</i>	1,4	5,7	4,2	3,325	6,3	3	4,9
<i>T 10% vol recobrado, °C</i>	175,9	272,5	268,6	104,0	105,0	208,8	257,1
<i>T 50% vol recobrado, °C</i>	211,3	303,6	295,3	204,0	205,0	273,1	298,8
<i>T 90% vol recobrado, °C</i>	244,9	359,2	345,7	355,4	335,0	327,4	354,1
<i>T 95% vol recobrado, °C</i>	320,0	383,0	351,3	340,0	340,8	412,0	372,8
<i>PFE, °C</i>	266,7	383,7	364,1	350,2	353,0	422,0	393,8
<i>Agua y Sedimento, ml / 100 ml</i>	0,05	0,00	0,05	0,00	0,00	0,05	0,02
<i>Punto de Inflamación, °C</i>	35,0	122,2	75,0	67,8	130,0	65,6	89,2
<i>Cenizas, g / 100 g</i>	0,01	0,00	0,01	0,00	0,00	0,00	0,00
<i>Porcentaje v/v SIN REMANENTE</i>	0,0	56,1	41,9	2,0	0,0	0,0	100,0
<i>Flujo, hr.</i>	0,0	1948,0	1454,0	68,0	0,0	0,0	3470
<i>Volumen, Bls</i>	0	46752	34896	1632	0	0	83280

Tabla 57. Primera corrida de preparación optimizada

<i>PARÁMETRO</i>	<i>JET HDT</i>	<i>ACPM HDT</i>	<i>ACEM</i>	<i>Biodiesel</i>	<i>Virginoil</i>	<i>Unibón</i>	<i>Diesel Regular</i>
<i>Azufre, ppm</i>	5,00	26,00	5	0	300	700	30
<i>Aromáticos, ml / 100 ml</i>	29,0	25,0	29,0	25,0	0,0	25,0	26,3
<i>Índice de Cetano f (T, API)</i>	39,0	51,6	49,5	41,1	32,1	50,0	49,0
<i>Índice de Cetano</i>	42,0	51,0	46,0	48,0	55,0	50,0	48,2
<i>Biocombustible, ml / 100 ml</i>	0,0	0,0	0,0	100,0	0,0	0,0	1,8
<i>Microcarbón Residual, g / 100 g</i>	0,01	0,01	0,01	0,01	0,00	0,01	0,01
<i>Gravedad API</i>	41,3	31,5	31,3	42,0	31,0	36,4	32,6
<i>Viscosidad a 40°C, mm²/s</i>	1,4	5,7	4,2	3,325	6,3	3	4,2
<i>T 10% vol recobrado, °C</i>	175,9	272,5	268,6	104,0	105,0	208,8	229,6
<i>T 50% vol recobrado, °C</i>	211,3	303,6	295,3	204,0	205,0	273,1	289,4
<i>T 90% vol recobrado, °C</i>	244,9	359,2	345,7	355,4	335,0	327,4	349,7
<i>T 95% vol recobrado, °C</i>	320,0	383,0	351,3	340,0	340,8	412,0	370,0
<i>PFE, °C</i>	266,7	383,7	364,1	350,2	353,0	422,0	392,9
<i>Agua y Sedimento, ml / 100 ml</i>	0,05	0,00	0,05	0,00	0,00	0,05	0,02
<i>Punto de Inflamación, °C</i>	35,0	122,2	75,0	67,8	130,0	65,6	69,6
<i>Cenizas, g / 100 g</i>	0,01	0,00	0,01	0,00	0,00	0,00	0,00
<i>Flujo, barriles/hora (bls/hr)</i>	429,5	1852,3	1500,0	72,0	100,0	46,2	4000
<i>Volumen, Bls</i>	10309	44455	36000	1728	2400	1108	96000

Tabla 58. Segunda corrida de preparación normal

<i>PARÁMETRO</i>	Jet HDT	ACPM HDT	ACEM	Biodiesel	Virginoil	Unibón	Diesel Regular
<i>Azufre, ppm</i>	5,00	26,00	7,8	0	300	700	19
<i>Aromáticos, ml / 100 ml</i>	29,0	25,0	29,0	25,0	0,0	25,0	26,5
<i>Índice de Cetano f (T,API)</i>	39,0	51,6	49,5	41,1	32,1	50,0	50,5
<i>Índice de Cetano</i>	42,0	51,0	46,0	48,0	55,0	50,0	49,0
<i>Biocombustible, ml / 100 ml</i>	0,0	0,0	0,0	100,0	0,0	0,0	2,3
<i>Microcarbon Residual, g / 100 g</i>	0,01	0,01	0,01	0,01	0,00	0,01	0,01
<i>Gravedad API</i>	41,3	31,5	31,3	42,0	31,0	36,4	31,6
<i>Viscosidad a 40°C, mm²/s</i>	1,4	5,7	4,2	3,325	6,3	3	5,0
<i>T 10% vol recobrado, °C</i>	175,9	272,5	268,6	104,0	105,0	208,8	255,3
<i>T 50% vol recobrado, °C</i>	211,3	303,6	295,3	204,0	205,0	273,1	298,9
<i>T 90% vol recobrado, °C</i>	244,9	359,2	345,7	355,4	335,0	327,4	354,6
<i>T 95% vol recobrado, °C</i>	320,0	381,9	351,3	340,0	340,8	412,0	372,9
<i>PFE, °C</i>	266,7	383,7	364,1	350,2	353,0	422,0	394,6
<i>Agua y Sedimento, ml / 100 ml</i>	0,05	0,00	0,05	0,00	0,00	0,05	0,02
<i>Punto de Inflamación, °C</i>	35,0	122,2	75,0	67,8	130,0	65,6	90,6
<i>Cenizas, g / 100 g</i>	0,01	0,00	0,01	0,00	0,00	0,00	0,00
<i>Flujo, barriles/hora (bls/hr)</i>	0,0	1897,0	1199,0	72,0	0,0	0,0	3168
<i>Volumen, Bls</i>	0	45528	28776	1728	0	0	76032

Tabla 59. Segunda Corrida de Preparación Optimizada

PARÁMETRO	JET HDT	ACPM HDT	ACEM	Biodiesel	Virginoil	Unibón	Diesel Regular
<i>Azúfre, ppm</i>	5,00	26,00	7,8	0	300	700	30
<i>Aromáticos, ml / 100 ml</i>	29,0	25,0	29,0	25,0	0,0	25,0	26,2
<i>Índice de Cetano f (T, API)</i>	39,0	51,6	49,5	41,1	32,1	50,0	49,3
<i>índice de Cetano</i>	42,0	51,0	46,0	48,0	55,0	50,0	48,4
<i>Biocombustible, ml / 100 ml</i>	0,0	0,0	0,0	100,0	0,0	0,0	1,8
<i>Microcarbon Residual, g / 100 g</i>	0,01	0,01	0,01	0,01	0,00	0,01	0,01
<i>Gravedad API</i>	41,3	31,5	31,3	42,0	31,0	36,4	32,4
<i>Viscosidad a 40°C, mm²/s</i>	1,4	5,7	4,2	3,325	6,3	3	4,3
<i>T 10% vol recobrado, °C</i>	175,9	272,5	268,6	104,0	105,0	208,8	232,7
<i>T 50% vol recobrado, °C</i>	211,3	303,6	295,3	204,0	205,0	273,1	291,3
<i>T 90% vol recobrado, °C</i>	244,9	359,2	345,7	355,4	335,0	327,4	350,8
<i>T 95% vol recobrado, °C</i>	320,0	381,9	351,3	340,0	340,8	412,0	370,0
<i>PFE, °C</i>	266,7	383,7	364,1	350,2	353,0	422,0	393,4
<i>Agua y Sedimento, ml / 100 ml</i>	0,05	0,00	0,05	0,00	0,00	0,05	0,02
<i>Punto de Inflamación, °C</i>	35,0	122,2	75,0	67,8	130,0	65,6	72,9
<i>Cenizas, g / 100 g</i>	0,01	0,00	0,01	0,00	0,00	0,00	0,00
<i>Flujo, barriles/hora (bls/hr)</i>	331,1	1960,1	1500,0	72,0	100,0	36,8	4000
<i>Volumen, Bls</i>	7947	47042	36000	1728	2400	883	96000

Tabla 60. Tercera Corrida de preparación normal

PARÁMETRO	Jet HDT	ACPM HDT	ACEM	Biodiesel	Virginoil	Unibón	Diesel Regular
<i>Azufre, ppm</i>	5,00	20,00	5	0	300	700	16
<i>Aromáticos, ml / 100 ml</i>	29,0	25,0	29,0	25,0	0,0	25,0	26,1
<i>Índice de Cetano f (T, API)</i>	39,0	51,6	49,5	41,1	32,1	50,0	50,8
<i>Índice de Cetano</i>	42,0	51,0	46,0	48,0	55,0	50,0	49,6
<i>Biocombustible, ml / 100 ml</i>	0,0	0,0	0,0	100,0	0,0	0,0	1,5
<i>Microcarbon Residual, g / 100 g</i>	0,01	0,01	0,01	0,01	0,00	0,01	0,01
<i>Gravedad API</i>	41,3	31,5	31,3	42,0	31,0	36,4	31,6
<i>Viscosidad a 40°C, mm²/s</i>	1,4	5,7	4,2	3,325	6,3	3	5,2
<i>T 10% vol recobrado, °C</i>	175,9	272,5	268,6	104,0	105,0	208,8	260,3
<i>T 50% vol recobrado, °C</i>	211,3	303,6	295,3	204,0	205,0	273,1	300,3
<i>T 90% vol recobrado, °C</i>	244,9	359,2	345,7	355,4	335,0	327,4	355,9
<i>T 95% vol recobrado, °C</i>	320,0	379,4	333,2	340,0	340,8	412,0	371,6
<i>PFE, °C</i>	266,7	383,7	364,1	350,2	353,0	422,0	395,8
<i>Agua y Sedimento, ml / 100 ml</i>	0,05	0,00	0,05	0,00	0,00	0,05	0,01
<i>Punto de Inflamación, °C</i>	35,0	122,2	75,0	67,8	130,0	65,6	95,6
<i>Cenizas, g / 100 g</i>	0,01	0,00	0,01	0,00	0,00	0,00	0,00
<i>Flujo, barriles/hora (bls/hr)</i>	0,0	2794,0	1095,0	61,0	0,0	0,0	3950
<i>Volumen, Bls</i>	0	67056	26280	1464	0	0	94800

Tabla 61. Tercera Corrida de preparación optimizada

<i>PARÁMETRO</i>	JET HDT	ACPM HDT	ACEM	Biodiesel	Virginoil	Unibón	Diésel Regular
<i>Azufre, ppm</i>	5,00	20,00	5	0	300	700	30
<i>Aromáticos, ml / 100 ml</i>	29,0	25,0	29,0	25,0	0,0	25,0	25,8
<i>Índice de Cetano f (T, API)</i>	39,0	51,6	49,5	41,1	32,1	50,0	50,1
<i>Índice de Cetano</i>	42,0	51,0	46,0	48,0	55,0	50,0	49,3
<i>Biocombustible, ml / 100 ml</i>	0,0	0,0	0,0	100,0	0,0	0,0	2,0
<i>Microcarbon Residual, g / 100 g</i>	0,01	0,01	0,01	0,01	0,00	0,01	0,01
<i>Gravedad API</i>	41,3	31,5	31,3	42,0	31,0	36,4	31,7
<i>Viscosidad a 40°C, mm²/s</i>	1,4	5,7	4,2	3,325	6,3	3	5,0
<i>T 10% vol recobrado, °C</i>	175,9	272,5	268,6	104,0	105,0	208,8	242,8
<i>T 50% vol recobrado, °C</i>	211,3	303,6	295,3	204,0	205,0	273,1	297,1
<i>T 90% vol recobrado, °C</i>	244,9	359,2	345,7	355,4	335,0	327,4	354,2
<i>T 95% vol recobrado, °C</i>	320,0	379,4	333,2	340,0	340,8	412,0	370,0
<i>PFE, °C</i>	266,7	383,7	364,1	350,2	353,0	422,0	395,2
<i>Agua y Sedimento, ml / 100 ml</i>	0,05	0,00	0,05	0,00	0,00	0,05	0,02
<i>Punto de Inflamación, °C</i>	35,0	122,2	75,0	67,8	130,0	65,6	89,7
<i>Cenizas, g / 100 g</i>	0,01	0,00	0,01	0,00	0,00	0,00	0,00
<i>Flujo, barriles/hora (bls/hr)</i>	25,8	2721,4	1500,0	90,0	100,0	62,8	4500
<i>Volumen, Bls</i>	619	65315	36000	2160	2400	1506	108000

Tabla 62. Cuarta Corrida de preparación normal

<i>PARÁMETRO</i>	Jet HDT	ACPM HDT	ACEM	Biodiesel	Virginoil	Unibón	Diesel Regular
<i>Azufre, ppm</i>	5,00	10,00	5	0	270	700	13
<i>Aromáticos, ml / 100 ml</i>	29,0	25,0	29,0	25,0	0,0	25,0	26,0
<i>Índice de Cetano f (T,API)</i>	39,0	51,6	49,5	41,1	32,1	50,0	50,2
<i>Indice de Cetano</i>	42,0	51,0	46,0	48,0	55,0	50,0	49,2
<i>Biocombustible, ml / 100 ml</i>	0,0	0,0	0,0	100,0	0,0	0,0	2,3
<i>Microcarbon Residual, g / 100 g</i>	0,01	0,01	0,01	0,01	0,00	0,01	0,01
<i>Gravedad API</i>	41,3	31,5	31,3	42,0	31,0	36,4	31,6
<i>Viscosidad a 40°C, mm2/s</i>	1,4	5,7	4,2	3,325	6,3	3	5,0
<i>T 10% vol recobrado, °C</i>	175,9	272,5	268,6	104,0	105,0	208,8	245,1
<i>T 50% vol recobrado, °C</i>	211,3	303,6	295,3	204,0	205,0	273,1	297,7
<i>T 90% vol recobrado, °C</i>	244,9	359,2	345,7	355,4	335,0	327,4	354,5
<i>T 95% vol recobrado, °C</i>	320,0	378,3	338,3	340,0	337,8	412,0	367,9
<i>PFE, °C</i>	266,7	383,7	364,1	350,2	353,0	422,0	395,3
<i>Agua y Sedimento, ml / 100 ml</i>	0,05	0,00	0,05	0,00	0,00	0,05	0,02
<i>Punto de Inflamación, °C</i>	35,0	122,2	75,0	67,8	130,0	65,6	91,4
<i>Cenizas, g / 100 g</i>	0,01	0,00	0,01	0,00	0,00	0,00	0,00
<i>Flujo, barriles/hora (bls/hr)</i>	0,0	2352,0	1400,0	90,0	71,0	0,0	3913
<i>Volumen, Bls</i>	0	56448	33600	2160	1704	0	103912

Tabla 63. Cuarta corrida de preparación optimizada

<i>Parámetro</i>	Jet HDT	Acpm HDT	Acem	Biodiese l	Virginoi l	Unibón	Diésel Regular
<i>Azufre, ppm</i>	5,00	10,00	5	0	270	700	30
<i>Aromáticos, ml / 100 ml</i>	29,0	25,0	29,0	25,0	0,0	25,0	25,9
<i>Índice de Cetano f (T,API)</i>	39,0	51,6	49,5	41,1	32,1	50,0	50,0
<i>Índice de Cetano</i>	42,0	51,0	46,0	48,0	55,0	50,0	49,2
<i>Biocombustible, ml / 100 ml</i>	0,0	0,0	0,0	100,0	0,0	0,0	2,0
<i>Microcarbón Residual, g / 100 g</i>	0,01	0,01	0,01	0,01	0,00	0,01	0,01
<i>Gravedad API</i>	41,3	31,5	31,3	42,0	31,0	36,4	31,9
<i>Viscosidad a 40°C, mm²/s</i>	1,4	5,7	4,2	3,325	6,3	3	4,8
<i>T 10% vol recobrado, °C</i>	175,9	272,5	268,6	104,0	105,0	208,8	240,3
<i>T 50% vol recobrado, °C</i>	211,3	303,6	295,3	204,0	205,0	273,1	295,8
<i>T 90% vol recobrado, °C</i>	244,9	359,2	345,7	355,4	335,0	327,4	353,5
<i>T 95% vol recobrado, °C</i>	320,0	378,3	338,3	340,0	337,8	412,0	370,0
<i>PFE, °C</i>	266,7	383,7	364,1	350,2	353,0	422,0	394,8
<i>Agua y Sedimento, ml / 100 ml</i>	0,05	0,00	0,05	0,00	0,00	0,05	0,02
<i>Punto de Inflamación, °C</i>	35,0	122,2	75,0	67,8	130,0	65,6	85,2
<i>Cenizas, g / 100 g</i>	0,01	0,00	0,01	0,00	0,00	0,00	0,00
<i>Flujo, barriles/hora (bls/hr)</i>	86,2	2615,6	1500,0	90,0	100,0	108,2	4500
<i>Volumen, Bls</i>	2070	62775	36000	2160	2400	2596	118000