

**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.**

JUAN CARLOS ARIAS MOLINA

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICOQUÍMICAS
ESCUELA DE INGENIERÍA QUÍMICA
BUCARAMANGA**

2016

**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.**

**Presentado por:
JUAN CARLOS ARIAS MOLINA
Ingeniero Químico**

Proyecto para optar por el Título de Magíster en Ingeniería Química

**Director:
Luis Javier López Giraldo
Ph. D Ingeniería Química**

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

2016

DEDICATORIA

Este trabajo de aplicación está dedicado a Dios porque siempre me ha bendecido en los proyectos de vida que he realizado.

A mi esposa Sara e hija María José por su comprensión y acompañamiento durante este camino de estudio. Las amo mucho son mi mayor fuente de inspiración.

A mis padres y hermanos que aunque están lejos geográficamente, siempre están en mis pensamientos y han sido un apoyo constante en este proceso. Los amo mucho.

Juan Carlos Arias Molina

AGRADECIMIENTOS

Quiero agradecer a la Empresa Colombiana de Petróleos ECOPEPETROL S.A. que representada por sus funcionarios Orlando Diaz Montoya, Carlos Guillermo Garcia, Ernesto Gomez Cabarcas, Marggy Liliana Santos y Edison Campos Garzon 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 los PhD Luis Javier Lopez, Luis Andres Rodriguez y Carlos Muvdi 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.

CONTENIDO

	Pág.
INTRODUCCION.....	18
1. PLANTEAMIENTO DEL PROBLEMA.....	23
2. HIPÓTESIS:	25
3. OBJETIVOS	26
3.1. OBJETIVO GENERAL.....	26
3.2. OBJETIVOS ESPECIFICOS.....	26
4. MARCO TEORICO	27
4.1. CARACTERIZACIÓN DEL CRUDO Y SUS FRACCIONES.	34
4.2. DESCRIPCIÓN UNIDAD DE DESTILACIÓN DE CRUDOS U150 SECCIÓN ATMOSFÉRICA.....	37
4.3. SOFT SENSOR.	52
5. METODOLOGIA.....	80
5.1. RECOLECCIÓN Y PRE PROCESAMIENTO DE DATOS HISTÓRICOS DE PLANTA Y LABORATORIO.....	81
5.1.1. Condiciones de operación.....	81
5.2. DEFINICIÓN DE LAS VARIABLES DE ENTRADA AL MODELO Y SUS INTERVALOS.....	88
5.2.1. Matriz dinámica del control avanzado de proceso U150.	89
5.2.2. Diagrama de relación de parámetros en destilación.....	89
5.2.3. Experiencia operativa.	90

5.2.4. Análisis de regresión lineal múltiple.	90
5.2.5. Definición de intervalos de las variables de entrada.....	91
5.3. CONSTRUCCIÓN, ENTRENAMIENTO Y VALIDACIÓN DE LA REDES NEURONALES.	92
5.3.1. Construcción de las redes neuronales.	92
5.3.2. Entrenamiento de las redes neuronales.....	99
5.3.3. Validación y prueba de las redes neuronales.....	101
6. RESULTADOS.....	104
6.1. RECOLECCIÓN Y PRE-PROCESAMIENTO DE DATOS HISTÓRICOS DE PLANTA Y LABORATORIO.....	104
6.2. DEFINICIÓN DE LAS VARIABLES DE ENTRADA AL MODELO Y SUS INTERVALOS.....	121
6.2.1. Matriz dinámica del control avanzado de proceso U150.	121
6.2.2. Diagrama de relación de parámetros en destilación.....	122
6.2.3. Experiencia operativa.	124
6.2.4. Análisis de regresión lineal múltiple.	124
6.3. CONSTRUCCIÓN, ENTRENAMIENTO Y VALIDACIÓN DE LAS REDES NEURONALES.	128
6.3.1. Resultados redes tipo multicapa para la predicción del PFE del Jet	130
6.3.2. Resultados redes tipo multicapa para la predicción de la T95 del ACPM..	139
6.3.3. Resultados redes tipo perceptron y base radial para la predicción del PFE del Jet y T95 del ACPM.	149
6.3.3.1. Resultado redes tipo base radial para la predicción del PFE del Jet y T95 del ACPM	152
6.4. ESTIMACIÓN DE BENEFICIOS POR IMPLEMENTACIÓN DEL SOFT SENSOR PARA PREDECIR EL PFE DEL JET Y T95 DEL ACPM EN U150.....	156
7. CONCLUSIONES.....	160

8. RECOMENDACIONES..... 162

BIBLIOGRAFIAS 163

LISTA DE TABLAS

	Pág.
Tabla 1. Productos U150	39
Tabla 2. Subproductos U150	39
Tabla 3. Tabla de control torre fraccionadora T150.....	46
Tabla 4. Funciones de Entrenamiento para redes neuronales multicapa	73
Tabla 5. Variables de Operación T150.....	83
Tabla 6. Variables Dependientes (Y) e Independientes (X).....	86
Tabla 7. Matriz Datos PFE Jet-A.....	87
Tabla 8. Matriz Datos T95 ACPM	87
Tabla 9. Redes Neuronales Construidas para predecir PFE del Jet A y T95 del ACPM.....	98
Tabla 10. Funciones de Entrenamiento para redes neuronales multicapa herramienta NNTOOL.....	100
Tabla 11. Estadístico de Cada Variable.	118
Tabla 12. Matriz Dinámica Control Avanzado de Proceso U150.	121
Tabla 13. Estadísticas Regresión Modelo para PFE Jet-A.....	124
Tabla 14. Coeficientes y Probabilidad Variables Modelo PFE Jet-A	125
Tabla 15. Estadísticas Regresión Modelo para T95 ACPM.....	125
Tabla 16. Coeficientes y Probabilidad Variables Modelo T95 ACPM	126
Tabla 17. Matriz datos para soft sensor PFE Jet A.	127
Tabla 18. Matriz datos para soft sensor T95 ACPM.....	127
Tabla 19. Intervalos Variables de Entrada	128
Tabla 20. Resultados Desempeño Redes Neuronales Tipo Multicapa para predecir PFE de Jet A y T95 del ACPM.....	129
Tabla 21. Resultados Desempeño Redes Neuronales Tipo Perceptron y Radial Basis para predecir PFE de Jet A y T95 del ACPM	149

LISTA DE FIGURAS

	Pág.
Figura 1. Esquema Típico de una unidad de destilación de crudos	28
Figura 2. Equipos de laboratorio utilizados para la prueba de destilación ASTM D86.....	35
Figura 3. Curvas de destilación ASTM D86 típicas para fracciones del petróleo...	37
Figura 4. Diagrama de Flujo Primer Tren de Precaliente, Desalado y Segundo Tren de Precaliente U150	43
Figura 5. Diagrama de Flujo Torre Preflash.	44
Figura 6. Diagrama de Flujo Torre Atmosférica.	45
Figura 7. Diagrama de Flujo Procedimiento de Modelado Basado en Datos de Planta.	55
Figura 8. Ejemplo de datos atípicos detectados usando la técnica de regresión lineal	61
Figura 9. Métodos de modelado usados para desarrollos de soft sensor.....	64
Figura 10. Función de Transferencia Log-Sigmoidal.....	69
Figura 11. Función de Transferencia Tag-Sigmoidea.	70
Figura 12. Función de Transferencia Lineal.	70
Figura 13. Red neuronal tipo multicapa feedforward.....	71
Figura 14. Funciones de transferencia base radial.	75
Figura 15. Red neuronal tipo base radial.	76
Figura 16. Funciones de transferencia <i>hard limit</i>	77
Figura 17 Red neuronal tipo perceptron.....	77
Figura 18. Diagrama de Flujo para diseño de una red neuronal	80
Figura 19. Diagrama de Flujo T150	81
Figura 20. Herramienta PI-Data Link-Excel empleado para Recopilar las Condiciones de Operación de la U150 durante los años 2013 al 2015	82

Figura 21. Herramienta CD-LAB para recopilar datos de laboratorio	84
Figura 22. Datos CD-LAB exportados a Excel.	85
Figura 23. Diagrama de Flujo Definición Variables de Entrada a Modelo.....	89
Figura 24. Herramienta Análisis de Datos Modulo Regresión Software Excel.....	91
Figura 25. Herramienta RIS Modulo Ventanas Operativas Consultas PCC.	92
Figura 26. Herramienta NFTOOL (NEURAL NETWORK FITTING TOOL).	93
Figura 27. Arquitectura de la red NFTOOL (NEURAL NETWORK FITTING).....	94
Figura 28. Ambiente para introducción de datos en la herramienta NFTOOL.	94
Figura 29. Herramienta NNTOOL (NEURAL NETWORK TOOL).....	95
Figura 30. Herramienta NNTOOL red neuronal tipo <i>perceptron</i>	96
Figura 31. Herramienta NNTOOL tipos de redes neuronales <i>radial basis</i>	96
Figura 32. Herramienta NNTOOL parámetros redes neuronales tipo <i>radial basis</i> .97	
Figura 33. Herramienta NFTOOL entrenamiento de la red.	99
Figura 34. Herramienta NFTOOL distribución de datos para entrenamiento.	101
Figura 35. Herramienta NFTOOL prueba adicional.....	102
Figura 36. Tendencia Punto Final de Ebullición (PFE) JET-A (Y1)	104
Figura 37. Tendencia T95%Vol de Recobrado ACPM (Y2).....	104
Figura 38. Tendencia Temperatura Salida Crudo H150 (X1)	105
Figura 39. Tendencia Temperatura Salida Reflujo Inferior T150 (X2)	106
Figura 40. Tendencia Temperatura Entrada Reflujo Inferior T150 (X3).....	107
Figura 41. Tendencia Flujo Reflujo Inferior T150 (X4).....	107
Figura 42. Tendencia Temperatura Salida Reflujo Medio T150 (X5).....	108
Figura 43. Tendencia Temperatura Entrada Reflujo Medio T150 (X6)	108
Figura 44. Tendencia Temperatura de Cima T150 (X7)	109
Figura 45. Tendencia Presión de Cima T150 (X8)	110
Figura 46. Tendencia Flujo Reflujo de Cima T150 (X9).	110
Figura 47. Tendencia Temperatura Salida ACPM T150 (X10)	111
Figura 48. Tendencia Temperatura Salida Jet-A T150 (X11)	112
Figura 49. Tendencia Flujo Producción de Jet-A T150 (X12).....	112
Figura 50. Tendencia Flujo Producción de ACPM T150 (X13)	113

Figura 51. Tendencia Flujo Vapor al Fondo T150 (X14)	114
Figura 52. Tendencia Flujo Vapor al Fondo T151A (X15)	114
Figura 53. Tendencia Flujo Vapor al Fondo T151B (X16)	115
Figura 54. Tendencia Flujo Vapor al Fondo T151C (X17)	115
Figura 55. Presión D150 (X18)	116
Figura 56. Flujo Reflujo Medio T150 (X19)	117
Figura 57. Tendencia Gravedad API Crudo (X20)	117
Figura 58. Residuos Estándar Pronostico PFE Jet-A.....	119
Figura 59. Residuos Estándar Pronostico T95 ACPM.....	120
Figura 60. Diagrama de Relación de Parámetros para Destilación. [14]	123
Figura 61. Estructura Red Multicapa No 5	130
Figura 62. Estructura Red Multicapa No 7	131
Figura 63. Estructura Red Multicapa No 25	131
Figura 64. Estructura Red Multicapa No 27	132
Figura 65. Estructura Red Multicapa No 31	133
Figura 66. Estructura Red Multicapa No 43	133
Figura 67. Resultados Coeficientes de Correlación R para las etapas de entrenamiento, validación y prueba de la red multicapa No 43 para predecir el PFE del Jet A	134
Figura 68. Resultados del promedio de los errores al cuadrado MSE de las etapas de entrenamiento, validación y prueba de la red multicapa No 43 para predecir el PFE del Jet A.....	134
Figura 69. Coeficiente de Correlación R Prueba 2 Red Multicapa No 43 para predicción PFE de Jet A	135
Figura 70. Promedio de los errores al cuadrado MSE Prueba 2 Red Multicapa No 43 para predicción PFE de Jet A	136
Figura 71. Resultados Coeficientes de Correlación R para las etapas de entrenamiento, validación y prueba de la red multicapa No 41 para predecir el PFE del Jet A	137

Figura 72. Resultados del promedio de los errores al cuadrado MSE de las etapas de entrenamiento, validación y prueba de la red multicapa No 41 para predecir el PFE del Jet A.....	137
Figura 73. Coeficiente de Correlación R Prueba 2 Red Multicapa No 41 para predicción PFE de Jet A	138
Figura 74. Promedio de los errores al cuadrado MSE Prueba 2 Red Multicapa No 41 para predicción PFE de Jet A	138
Figura 75. Estructura Red Multicapa No 44	140
Figura 76. Estructura Red Multicapa No 44	141
Figura 77. Estructura Red Multicapa No 32	141
Figura 78. Estructura Red Multicapa No 26	142
Figura 79. Estructura Red Multicapa No 12	143
Figura 80. Estructura Red Multicapa No 6	143
Figura 81. Resultados Coeficientes de Correlación R para las etapas de entrenamiento, validación y prueba de la red multicapa No 24 para predecir la T95 del ACPM.	144
Figura 82. Resultados del promedio de los errores al cuadrado MSE de las etapas de entrenamiento, validación y prueba de la red multicapa No 24 para predecir la T95 del ACPM	144
Figura 83. Coeficiente de Correlación R Prueba 2 Red Multicapa No 24 para predicción T95 del ACPM	145
Figura 84. Promedio de los errores al cuadrado MSE Prueba 2 Red Multicapa No 24 para predicción de la T95 del ACPM.....	145
Figura 85. Estructura Red Multicapa No 20	146
Figura 86. Resultados Coeficientes de Correlación R para las etapas de entrenamiento, validación y prueba de la red multicapa No 20 para predecir la T95 del ACPM.	147
Figura 87. Resultados del promedio de los errores al cuadrado MSE de las etapas de entrenamiento, validación y prueba de la red multicapa No 20 para predecir la T95 del ACPM	147

Figura 88. Coeficiente de Correlación R Prueba 2 Red Multicapa No 20 para predicción T95 del ACPM	148
Figura 89. Promedio de los errores al cuadrado MSE Prueba 2 Red Multicapa No 20 para predicción de la T95 del ACPM.....	148
Figura 90. Estructura Red Multicapa No 45	150
Figura 91. Coeficiente de Correlación R etapa de prueba Red <i>Perceptron</i> No 45 para predicción del PFE del Jet A.....	150
Figura 92. Promedio de los errores al cuadrado MSE Prueba Red <i>Perceptron</i> No 45 para predicción del PFE del Jet A.....	151
Figura 93. Resultados del promedio del error absoluto de las etapa de entrenamiento de la red <i>perceptron</i> No 45 para predecir el PFE del Jet A.....	151
Figura 94. Estructura Red Radial Basis No 51	153
Figura 95. Coeficiente de Correlación R etapa de prueba Red Radial Basis No 51 para predicción del PFE del Jet A.....	153
Figura 96. Resultado del promedio del error al cuadrado MSE de la etapa de prueba de la red <i>perceptron</i> No 51 para predecir el PFE del Jet A.	153
Figura 97. Estructura Red Radial Basis No 51	154
Figura 98. Coeficiente de Correlación R etapa de prueba Red <i>Radial Basis</i> No 52 para predicción de la T95 del ACPM.	155
Figura 99. Resultado del promedio del error al cuadrado MSE de la etapa de prueba de la red <i>perceptron</i> No 52 para predecir la T95 del ACPM.....	155
Figura 100. PFE del Jet T150 respecto a valor máximo esperado.	157
Figura 101. T95 del ACPM T150 respecto a valor máximo esperado.	158

RESUMEN

TÍTULO: 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.*

AUTORES: Juan Carlos Arias Molina **

PALABRAS CLAVES: Modelización., Analizador Virtual (*Soft Sensor*), Destilación de Crudos, Punto Final de Ebullición (PFE), Destilación T95% vol. (T95), Gravedad API, Jet-A.

DESCRIPCIÓN

Considerando la alta variabilidad en la composición de los crudos cargados en la U150 y el estricto requerimiento de mantener la calidad y rendimiento de los productos valiosos como los destilados medios (JetA-ACPM), es necesario obtener con oportunidad los resultados de las pruebas de laboratorio para control de calidad y optimización de la operación. Por esta razón en este trabajo como alternativa a las pruebas de laboratorio se desarrollaron modelos de *soft-sensor* para estimar los parámetros de calidad PFE del JetA y T95 del ACPM producidos en la U150. Datos históricos previamente procesados de Julio/2013 a Octubre/2015 que incluyen mediciones continuas disponibles en la base de datos *PIdata-link* de condiciones de operación preliminarmente definidas (temperatura, presiones y flujos) de la torre fraccionadora T150 y resultados de laboratorio de la base datos CdLab de los parámetros de calidad a predecir y la gravedad API del crudo cargado fueron utilizados para el desarrollo del modelo. Los modelos de *soft-sensor* se desarrollaron a través del método de modelización de redes neuronales en el software MATLAB®-R2012b estudiando diferentes tipos de configuraciones tales como perceptron, multicapa y base radial. A través de los parámetros estadísticos de desempeño R y *MSE*, se validaron y probaron las redes neuronales construidas obteniendo que las que presentan el mejor desempeño son las multicapa ($R = 0.84$, $MSE = 144.2$) y base radial ($R = 0.99$, $MSE = 3.26$). Para el caso de las multicapa se evaluaron también diferentes números de capas, neuronas, funciones de transferencia y de entrenamiento. Los resultados muestran los modelos *soft-sensor* para estimar el PFE del JetA y T95 del ACPM como una alternativa viable frente a las pruebas de laboratorio y que pueden ser implementados en el modelo del CAP instalado en la U150 para controlar la calidad y maximizar la producción de los destilados medios.

* Trabajo de grado.

** Facultad de Ingenierías Físicoquímicas. Maestría en Ingeniería Química. PhD Luis Javier Lopez.

ABSTRACT:

TITLE: PROPOSAL FOR A VIRTUAL ANALYZER (SOFT-SENSOR) FOR PREDICTION END BOILING POINT OF JET AND T95 OF ACPM IN UNIT PROCESSING OF CRUDE OIL U150 REFINERY MANAGEMENT BARRANCABERMEJA, ECOPETROL S.A.

AUTHORS: Juan Carlos Arias Molina **

KEY WORDS: Modeling, Virtual Analyzer (*Soft Sensor*), Distillation of Crude Oil, End Boiling Point (EBP), Distillation T95% vol. (T95), API Gravity, Jet-A, ACPM (Diesel).

DESCRIPTION

Considering the high variability in the composition of crude oil charged in the U150 and the strict requirement to maintain the quality and yield of valuable products such as are middle distillates (JetA-ACPM), is necessary to obtain the results of laboratory tests with opportunity for quality control and optimization of the operation. For this reason, in this paper as an alternative to laboratory testing was developed models of soft-sensor to estimate the quality parameters EBP of JetA and T95 of the ACPM produced in U150. Historical data collected since July/2013 to October/2015 whichs include continuous measurements available in the database of Pldata-link of operation conditions preliminarily defined (temperature, pressure and flow) in the fractionation tower T150 and laboratory results in the database CdLab of quality parameters to predict and API gravity crude loaded were used for develop the model. Soft-sensor models were developed using neural network modeling in the software MATLAB®-R2102b studying different types of configurations such as perceptron, radial basis and multilayer. Through of statistical performance parameters as R and MSE were validated and tested neural networks constructed obtaining that present the best performance are the multilayer type (R = 0.84, MSE= 144.2) and radial base (R = 0.99, MSE= 3.26). In the case of multilayer type layers different numbers of neurons and transfer functions of training were also evaluated. The results show the soft-sensor models to estimate the EBP of JetA and T95 of the ACPM as a viable alternative to laboratory tests and can be implemented in the model of APC installed the U150 for quality control and maximize the production of middle distillates.

* Working Grade

** Physicochemical Faculty of Engineering, Master of Chemical Engineering, PhD Luis Javier Lopez.

INTRODUCCION

En la actualidad los sistemas de medición *Soft Sensor* (Sensores Virtuales) están siendo ampliamente utilizados en los procesos industriales para el monitoreo en línea de parámetros de calidad de productos (Variables de Salida) de difícil medición, para los cuales no existen sistemas de medición en línea (*Hardware Sensor*) y que solo pueden ser determinados a través de análisis de laboratorio de muestras periódicas. Lo anterior trae consigo un aumento en los tiempos para la obtención de información oportuna y en los costos de instrumentación cuando los *Hardware Sensor* están disponibles. Adicionalmente los *Soft Sensor* también aparecen como una alternativa de relevo cuando los *Hardware Sensor* fallan o se sacan de servicio para mantenimiento ¹.

Los sistemas de medición *Soft Sensor* se basan en modelos matemáticos que generalmente se construyen a partir de datos reales de proceso (Datos de Planta y Datos Históricos) obtenidos a través de la operación normal de la planta. Estos modelos buscan conectar variables de entrada de fácil medición con variables de salida de difícil medición. En la construcción de estos modelos lo que se pretende es encontrar una función de aproximación que represente la dependencia entre las variables de entrada y de salida del proceso. Existen varios métodos para la construcción de modelos basados en datos de proceso entre los cuales se encuentran: estadística multivariable, ANN (*Artificial Neural Networks*), SVM (*Support Vector Machines*), SVR (*Support Vector Regresión*), métodos híbridos (PCA no Lineal, PLS no Lineal y Multimodelo) y métodos adaptativos².

¹ D. SLISKOVIC, R. GRBIC, and Z. HOCENSKI, Methods for Plant Data-Based Process Modeling in Soft-Sensor Development, *Automatica* 52, Vol 4, págs 306-318, 2011.

² Ibid

De acuerdo con la revisión del estado del arte se han realizado varios trabajos sobre los sistemas de medición *soft sensor* para diferentes campos de la industria. Algunos ejemplos son: (i) Dong *et al.* (1995), muestran el uso de un *soft sensor* para el monitoreo de NOx en los gases de combustión de un horno industrial³; (ii) Luo *et al.* (1995) proponen un *soft sensor* para la predicción de la composición de propileno en una columna de destilación de alta pureza⁴; (iii) Casali *et al.* (1998) usaron un *soft sensor* para predecir la distribución de tamaño de partícula en un circuito de trituración⁵; (iv) Bhat *et al.* (2003) presentan un *soft sensor* para la predicción de propiedades de productos y procesamiento de datos en línea para unidades de destilación de crudos⁶ (v) Fortuna *et al.* (2005) desarrollaron un *Soft Sensor* para el monitoreo de la calidad de productos en una columna de destilación debutanizadora⁷; (vi) Macias *et al.* (2006) construyeron un *soft sensor* usando un método de modelización en tiempo real llamado extended involving fuzzy Takagi-Sugeno models (xTS) para predecir en línea la destilación y punto de inflamación del queroseno⁸; (vii) Bolf *et al.* (2008) elaboraron un *soft sensor* para la estimación y control de la propiedades del queroseno en una unidad de destilación de crudo⁹; (viii) Mohler *et al.* (2010) generaron un *soft sensor* utilizando el método de regresión lineal y redes neuronales artificiales para predecir el punto de ebullición T95 del diésel¹⁰; (viii) Rogina *et al.* (2011) crearon un *soft sensor* para

³ D. DONG, T. MCAVOY, and L. CHANG, Emission monitoring using multivariate soft sensors, Proceedings of the American Control Conference, Vol 1, págs.761-765, 1995.

⁴ R. LUO, H. SHAO, and Z. ZHANG, Fuzzy-neural-netbased inferential control for a high-purity distillation column, Control Engineering Practice, Vol 3, págs 31-40, 1995.

⁵ A. CASALI, G. GONZALEZ, F. TORRES, G. VALLEBUONA, L. CASTELLI, and P. GIMENEZ, Particle size distribution soft-sensor for a grinding circuit, Powder technology, Vol 99, págs 15-21, 1998.

⁶ S. BHAT, T. CHATTERJEE, and N. SARAF, On-Line data processing and product properties prediction for crude distillation units, Journal of process control Vol 14, págs 61-77, 2004.

⁷ L. FORTUNA, S. GRAZIANI, and M. XIBILIA, Soft sensors for product quality monitoring in debutanizer distillation columns, Control Engineering Practice, Vol 13, págs 499-508, 2005.

⁸ J. MACIAS, P. ANGELOV, and Y. ZHOU, Soft sensors for predicting crude oil distillation side streams using involving Takagi-Sugeno fuzzy models. Result outlined, Proceedings of 2nd Intern. Symposium on evolving fuzzy systems, págs 214-220, 2006.

⁹ N. BOLF, M. IVANDIC, and G. GALINEC, Soft sensors for crude distillation unit product properties and estimation and control, Control and automation, Vol 16, págs 1804-1809, 2008.

¹⁰ I. MOHLER, G. GALINEC, N. HOLBLING, N. BOLF and Z. UJEVIC, Soft sensors for diesel fuel property estimation, Chemical Engineering Transactions, Vol 21, 2010.

estimación continua de la presión de vapor de la nafta liviana de una unidad de destilación de crudo¹¹.

En los trabajos anteriormente mencionados se destacan los métodos de modelización PLS (Partial Least Squares), PCA (Principal Component Analysis) y ANN. El método más utilizado cuando la relación de variables del proceso a modelar describe un comportamiento ligeramente no lineal es el PLS, y para procesos con relación de variables con comportamiento fuertemente no lineal el más utilizado es el de redes neuronales artificiales (ANN) y su combinación con PCA y PLS.¹²

De acuerdo con los resultados obtenidos por Fortuna *et al.* (2005), Bolf *et al.* (2008), Mohler *et al.* (2010) y Rogina *et al.* (2011), para sensores *soft sensor* de uso en las unidades de destilación, el método utilizado para la modelización es el ANN debido a que la relación de variables para este proceso presenta un comportamiento no lineal. En dichos trabajos las variables de entrada empleadas para el modelamiento son las temperaturas, presiones y flujos de las corrientes de proceso, para predecir de manera continua parámetros de calidad (densidades, puntos de inflamación, presiones de vapor, puntos de congelamiento, puntos de fluidez etc.) de los productos obtenidos en las torres de fraccionamiento.

En el trabajo publicado por Molher *et al.* (2010) se utilizaron redes neuronales tipo MLP (*Multilayer Perceptron*) y RBN (*Radial Basis Network*) tomando como variables de entrada al modelo condiciones de operación de una torre fraccionadora de crudo tales como temperatura salida del Jet A, temperatura salida del gasóleo liviano, temperatura salida de gasóleo pesado, temperatura de salida de gasolina pesada y temperatura de entrada del reflujo de cima con

¹¹ A. ROGINA, L. SSKO, I. MOLHER, Z. UJEVIC and N. BOLF, Soft sensors for continuous product quality estimation (in crude distillation unit), Chemical engineering research and design, Vol 89, págs 2070-2077, 2011.

¹² D. SLISKOVIC, R. GRBIC, and Z. HOCENSKI, Methods for Plant Data-Based Process Modeling in Soft-Sensor Development, Automatica 52, Vol 4, págs 306-318, 2011.

resultados satisfactorios en los parámetros de desempeño (coeficiente de correlación y error absoluto promedio con valores de 0.82 y 7.82 respectivamente)¹³. De igual manera en el trabajo publicado por *Rogina et al.*(2011) los modelos *soft sensor* no lineales utilizando redes neuronales de tipo MLP y RBN muestran resultados con desviaciones (Error absoluto promedio <0.06) dentro un rango aceptable e indicadores estadísticos (Coeficiente de correlación >0.8)¹⁴ que sugieren que estos modelos de redes neuronales pueden ser usados para estimar de manera continua el RVP (*Reid Vapor Pressure*) de la nafta liviana y la T95 del diésel (ACPM) de una unidad de destilación de crudo a través de datos de operación disponibles de los equipos y corrientes de proceso medidos en línea tales como temperaturas, flujos y presiones.

De acuerdo con lo expuesto en los párrafos anteriores, en este trabajo se empleara el método de modelización de redes neuronales artificiales ANN (Artificial Neural Networks) para el desarrollo del *soft sensor* que prediga el punto final de ebullición del Jet A y T95 del ACPM en la unidad de destilación de crudos U150, a partir de las condiciones de operación de la torre fraccionadora T150 (presiones, temperaturas y flujos) y calidad de crudo cargado (gravedad API). Los datos usados corresponden a los históricos comprendidos entre Julio de 2013 a Octubre de 2015.

La estructura del presente trabajo de aplicación será la siguiente: en el primer y segundo capítulo se mostrará el **planteamiento del problema e hipótesis** donde se expone la necesidad que se busca satisfacer en la gerencia refinería de Barrancabermeja y el cómo se lograra.

¹³ I. MOHLER, G. GALINEC, N. HOLBLING, N. BOLF and Z. UJEVIC, Soft sensors for diesel fuel property estimation, Chemical Engineering Transactions, Vol 21, 2010.

¹⁴ A. ROGINA, L. SSKO, I. MOLHER, Z. UJEVIC and N. BOLF, Soft sensors for continuous product quality estimation (in crude distillation unit), Chemical engineering research and design, Vol 89, págs 2070-2077, 2011.

En el tercer capítulo se plantean el objetivo general y los objetivos específicos. Seguidamente, en el capítulo cuatro se mostrara el **marco conceptual** donde se hablará de los conceptos teóricos utilizados para el desarrollo de este trabajo tales como los fundamentos de la destilación de crudos, modelos *soft sensor* y redes neuronales artificiales.

En el quinto capítulo se encuentra la **metodología** donde se describen la secuencia de actividades y métodos que se llevaron a cabo para lograr los objetivos del trabajo, entre los que se destacan la recolección y pre-procesamiento de datos, definición de las variables de entrada al modelo y sus intervalos, construcción, entrenamiento y validación de las redes neuronales desarrolladas para la predicción del PFE del Jet y T95 del ACPM.

Finalmente en el sexto y séptimo capítulo se mostraran los **resultados** y análisis del estudio realizado, así como también **las conclusiones y recomendaciones**; así mismo se enfatiza sobre los resultados más importantes que pueden llevar al desarrollo de trabajos y/o investigaciones posteriores.

Las referencias bibliográficas citadas durante el desarrollo del trabajo también son presentadas al final del documento.

1. PLANTEAMIENTO DEL PROBLEMA

La Refinería de Barrancabermeja cumple un importante papel en la evacuación de crudo de los campos de producción mediante la maximización y sostenibilidad en la capacidad de procesamiento en las unidades de destilación de crudo que conlleva a mantener el mínimo inventario posible de crudo en los tanques de almacenamiento.

Teniendo en cuenta la amplia diversidad de crudos que se reciben en la refinería, mantener el mínimo inventario posible de crudo trae consigo un reto para la operación de las unidades de proceso. Esta complejidad se debe al aumento en la variabilidad composicional y la disminución en los tiempos de preparación y homogenización de mezclas de crudo en los tanques de carga para las unidades de destilación.

Con esta alta variabilidad en la composición de carga, el reto para las unidades de destilación de crudos consiste en sostener la producción y la calidad de los productos, entre los que se encuentran naftas, destilados medios (Jet - ACPM) y gasóleos.

Los destilados medios (Jet - ACPM) son productos de alto valor que requieren un control estricto en su producción y calidad, las variaciones negativas en estos parámetros afectan la economía de la refinería en 26,23 US\$ por barril de destilados medios que se dejen de producir¹⁵.

¹⁵ ECOPETROL, W:\Planeación de la producción \Planeación y Programación de la Producción\Análisis Económicos\Potenciales, 2014.

La unidad de destilación de crudos U150 que está diseñada para procesar crudos parafínicos es la que tiene una mayor variabilidad en su carga por la baja disponibilidad de crudos Cupiagua y Cusiana (40 – 46 API). Para garantizar la carga a esta unidad, actualmente los crudos Cupiagua y Cusiana se están mezclando con crudos intermedios procedentes de diferentes campos. Esta mezcla denominada Oensa es la más liviana (36-38API) cargada en la refinería por tanto es la que tiene el mayor porcentaje de Naftas (Gasolinas) y destilados medios (Jet + ACPM). En el futuro inmediato se prevé que la gravedad API de las mezclas cargadas a esta unidad siga disminuyendo haciendo que los rendimientos hacia destilados medios sean cada vez menores.

Bajo este escenario, este trabajo busca brindar una herramienta (*Soft Sensor*) en la U150 que permita a partir de variables de entrada al proceso (composición de la carga y condiciones de operación) obtener en línea el punto final de ebullición y T95 para el Jet y ACPM respectivamente, siendo éstos los más importantes parámetros de control para maximizar rendimientos y sostener la calidad en dichos productos.

2. HIPÓTESIS:

A través de un *soft sensor* desarrollado con el método de modelización de redes neuronales artificiales se puede predecir el punto final de ebullición del JET y T95 del ACPM de la U150 a partir de las condiciones de operación (temperaturas, flujos y presiones) de la torre fraccionadora T150 y calidad (gravedad API) del crudo cargado.

3. OBJETIVOS

3.1. OBJETIVO GENERAL

Proponer un modelo de Analizador Virtual (*Soft Sensor*) para la predicción del punto final de ebullición del Jet y T95 del ACPM de la unidad de procesamiento de crudos U150 de la Gerencia Refinería de Barrancabermeja.

3.2. OBJETIVOS ESPECIFICOS

- Definir las variables de entrada y su intervalo de evaluación para el desarrollo del *Soft Sensor*.
- Estudiar diferentes tipos de configuraciones de redes neuronales para la predicción del punto final de ebullición y T95 del Jet y ACPM respectivamente en la U150
- Validar la capacidad de predicción del *Soft Sensor* comparando su valor predictivo con datos reales de laboratorio.

4. MARCO TEORICO

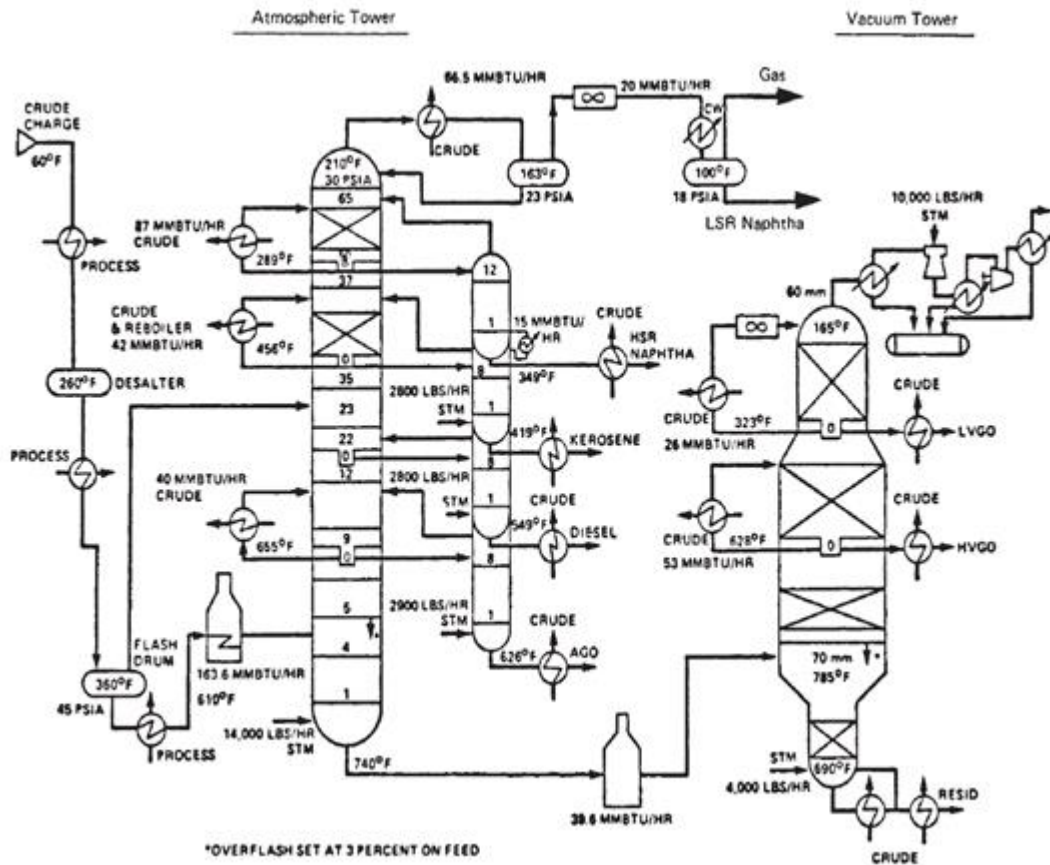
Como bases teóricas para este trabajo de aplicación se hablará sobre el proceso de destilación de crudos, caracterización del crudo y sus fracciones, se describirá la unidad de destilación de crudos U150 para donde se desarrollará el *soft sensor* y finalmente se hablará sobre la teoría de los *soft sensor* y el método de modelización de redes neuronales artificiales.

Destilación de Crudos.

La destilación es un proceso para separar los componentes de una solución que se basa en el enriquecimiento de las fases (Vapor/Líquido) que ocurre durante la evaporación y condensación, la destilación del petróleo o crudo en sus fracciones es un ejemplo de esto.

La configuración típica de una planta de destilación de crudo se muestra se muestra en la figura 1:

Figura 1. Esquema Típico de una unidad de destilación de crudos



Fuente: R. Perry, Manual del Ingeniero Químico, Destilación, Vol 2, Cap 13, 1997.

Como se muestra en la figura 1 la destilación del crudo a presión atmosférica permite su separación en gas licuado del petróleo (GLP), gasolina (nafta), queroseno (Jet-A), combustible diésel (ACPM), gasóleo y residuo (crudo reducido). La destilación es una operación de refinación en la cual los vapores que ascienden a través de los platos de fraccionamiento de una columna se ponen en contacto íntimo con el líquido descendente, con lo cual los componentes más pesados condensan y se concentran en el fondo mientras que los compuestos ligeros se vaporizan y se extraen en la cima¹⁶

¹⁶ UOP Inc, Tyro, Manual de Entrenamiento, Cap 20-21, 1978.

A fin de reducir el costo de la operación de una unidad de fraccionamiento de crudos, se procura recuperar tanto calor como sea posible por medio del intercambio térmico entre las corrientes calientes (Productos y Reflujos) y las frías (Crudo). El número de intercambiadores en una unidad de crudos varía según el diseño¹⁷.

La mayor parte de los crudos contienen trazas de sal que se descomponen en los tubos del horno, dando lugar a la formación de ácido clorhídrico que corroe el equipo de cabeza de la columna de fraccionamiento. A fin de remover esta sal, se inyecta agua en el crudo algo precalentado y la mezcla se agita para extraer prácticamente toda la sal que pudiera haber en el crudo. La mezcla de petróleo y de agua se separa en el desalador, que es un recipiente grande en el que el agua se decanta del crudo.

Este proceso de decantado puede ser acelerado por medio de métodos químicos o eléctricos. La solución acuosa salina se saca automáticamente del fondo del recipiente¹⁸.

El crudo desalado intercambia térmicamente con otras corrientes calientes que pudiera haber a fin de recuperar una máxima cantidad de calor antes de circularlo por el horno de calefacción, el cual suministra todo el calor adicional necesario para la operación de la unidad¹⁹.

El suministro de calor se regula haciendo que la temperatura de salida del horno controle el flujo de combustible a los quemadores. Esta temperatura de transferencia es solamente un parámetro de control conveniente y puede variar

¹⁷ Ibid

¹⁸ Ibid

¹⁹ Ibid

desde 325°C hasta 430°C según sea el tipo de crudo y la presión en el fondo de la columna de fraccionamiento²⁰.

El crudo que entra en la zona de *flash* de una columna de fraccionamiento se vaporiza rápidamente en vapor que asciende hacia lo alto de la columna mientras que el residuo líquido desciende hacia el fondo. Este *flash* es sólo una separación grosera ya que los vapores todavía contienen cantidades apreciables de compuestos pesados, mientras que el líquido contiene compuestos ligeros que deben ser desorbidos antes de extraer el residuo líquido por el fondo de la columna²¹.

Los vapores que ascienden por la columna entran en contacto con el reflujo líquido interno que desciende por la columna. El producto más ligero, que es normalmente gasolina, sale en cabeza y es condensado y recogido en el acumulador de cabeza. Si el crudo contiene gases incondensables, estos saldrán también en cabeza, pero saldrán del acumulador en forma de gas y deberán ser recuperados en otra parte de la unidad. La temperatura en cabeza de la torre de fraccionamiento corresponde al punto final de destilación de la fracción gasolina y se controla por medio del retorno de parte de la gasolina condensada en forma de reflujo externo. Un aumento en el caudal de reflujo corresponde a una disminución en la temperatura de cabeza y produce un producto de cabeza con un punto de destilación final más bajo²².

Si se produce menos producto de cima se producirá mayor cantidad de la fracción siguiente, por lo que el punto de ebullición inicial de esta fracción disminuirá. Aumentando la temperatura de transferencia en el horno se aumenta el suministro de calor, por lo que se requiere un mayor caudal de reflujo para mantener la misma temperatura en la cima. El reflujo externo que se introduce en la cabeza de

²⁰ Ibid

²¹ Ibid

²² Ibid

la torre de fraccionamiento fluye hacia abajo a contracorriente de los vapores ascendentes. Los componentes más ligeros del reflujo se revaporizan y regresan a la cima de la columna mientras que los componentes más pesados del vapor se condensan y fluyen hacia abajo. El líquido que desciende por la columna constituye por tanto un reflujo interno cuya concentración de productos pesados aumenta progresivamente a medida que desciende por la columna²³.

Los productos más pesados que el producto de cima se extraen de puntos intermedios de la columna en forma de cortes laterales. El punto de destilación final de estos cortes laterales depende de la cantidad extraída. Si se aumenta el caudal de salida de un corte lateral, el producto adicional es un material que de otro modo habría descendido más abajo en la columna en forma de reflujo interno. De esta manera se ha reducido el caudal de reflujo interno por debajo del punto de salida del corte lateral, el enriquecimiento a contracorriente disminuye y vapores relativamente más pesados pueden elevarse hasta este corte lateral, por lo cual el producto es más pesado. Cambiando el caudal de salida del corte lateral es la manera común de lograr que los puntos finales de destilación de los cortes laterales se ajusten a las especificaciones²⁴.

Las temperaturas en los platos de salida de los cortes laterales proporcionan una buena indicación de los puntos finales de destilación de los cortes laterales respectivos, por lo que un operario con experiencia se limita simplemente a variar el caudal de salida de los cortes laterales a fin de mantener una temperatura de plato constante y, por tanto, un producto que se ajuste a unas especificaciones dadas.²⁵

El grado de fraccionamiento entre cortes se determina generalmente midiendo el número de grados centígrados entre el punto en que se ha destilado el 95 % (T95)

²³ UOP Inc, Tyro, Manual de Entrenamiento, Cap 20-21, 1978.

²⁴ Ibid

²⁵ Ibid

del producto ligero y el punto en que se ha destilado el 5% del producto pesado. (También se puede usar el punto de ebullición inicial y el punto de ebullición final, pero el punto de ebullición inicial varía con la desorción o stripping.) El espaciado entre gasolina y queroseno (Jet) debería ser de unos 5°C, mientras que el margen normal entre Jet y un ACPM es de 3°C. El fraccionamiento puede mejorarse aumentando el reflujo en la columna de fraccionamiento por medio de un aumento en la temperatura de transferencia del horno. Sin embargo, puede ocurrir a veces que el reflujo necesario para una separación satisfactoria es tan grande que los platos superiores podrían inundarse si todo el reflujo externo fuese introducido en cabeza de la columna. En estos casos se utiliza un “reflujo circulante intermedio”. Para esto se extrae algo de líquido de la columna, se enfría, y se retorna a la columna en un punto situado a unos cuantos platos por encima del punto de extracción. Este retorno frío basta para condensar parte de los vapores y así aumentar el reflujo interno por debajo del punto de retorno. De esta forma podemos mejorar el fraccionamiento sin tener que recurrir a un excesivo reflujo externo en cabeza, a base de aumentar el caudal de reflujo circulante. Debe advertirse que, aunque se ha aumentado la temperatura de transferencia en el horno, el calor adicional se recupera por medio del intercambio térmico con crudo frío con lo cual los requerimientos energéticos del horno sólo aumentan ligeramente²⁶.

Tanto el residuo en el fondo de la columna como los cortes laterales han estado en contacto con vapores más ligeros. Cualquiera de estos vapores que pudieran haber sido absorbidos deben ser desorbidos a fin de que los líquidos se ajusten a sus respectivas especificaciones de punto de ignición (flash) y a fin de recuperar una máxima cantidad de productos ligeros, que normalmente son más valiosos²⁷. La desorción normalmente se hace por medio de vapor recalentado. Normalmente sólo se utiliza la cantidad de vapor mínima requerida para ajustarse a las

²⁶ Ibid

²⁷ Ibid

especificaciones del punto de ignición (flash). Puede usarse una cantidad de vapor adicional para aumentar el punto de ebullición inicial del producto, pero esto normalmente se hace de forma más práctica a base de aumentar el caudal relativo de las fracciones más ligeras, siempre y cuando la torre de fraccionamiento tenga suficiente reflujo interno para lograr una buena separación²⁸.

Todo el vapor de desorción se condensa en el acumulador de cabeza y debe ser decantado y separado. La presencia de agua en el reflujo perjudicaría la separación en la columna de fraccionamiento. Si el punto final de ebullición del producto de cabeza es demasiado bajo, el agua no podrá condensar en cabeza, se acumulará en los platos superiores de la columna y producirá su inundación²⁹.

A fin de maximizar la producción de gasoil y de componentes ligeros a partir del material de fondos de una unidad de destilación atmosférica, estos fondos (crudo reducido) pueden ser destilados en una unidad de destilación a vacío. La destilación de aceites pesados se lleva a cabo a baja presión a fin de evitar la descomposición térmica o cracking a elevadas temperaturas. Un material que hierve a 400°C a 50 mm Hg probablemente no herviría hasta unos 500°C a presión atmosférica. A estas temperaturas elevadas la mayoría de los hidrocarburos se descomponen. En una unidad de vacío no se tiene demasiado interés en fraccionar los productos. Lo que se intenta hacer es destilar el gasoil, remover la brea o alquitrán, y condensar el producto de la manera más conveniente posible. Las unidades de vacío para la fabricación de aceites lubricantes son totalmente distintas tanto en diseño como en operación³⁰.

El crudo reducido se alimenta a la unidad de vacío a través de un horno, de la misma manera que un crudo normal se alimenta a una unidad atmosférica. Sin embargo, mientras que la presión en la zona de flash de una columna atmosférica

²⁸ Ibid

²⁹ Ibid

³⁰ Ibid

puede ser de unos 1 a 1,3 kg/cm², la presión en una columna de vacío es mucho más baja. Aunque la temperatura de transferencia del horno también se utiliza para fines de control, carece de significado preciso debido a la caída de presión en la tubería de transferencia. La temperatura en la zona de flash posee un significado mejor definido. Las temperaturas de transferencia del horno y de la zona de flash se controlan para ajustarse a especificaciones tales como la densidad o viscosidad de un aceite pesado (fuel oil) o la penetración de un asfalto³¹.

4.1. CARACTERIZACIÓN DEL CRUDO Y SUS FRACCIONES.

Para propósitos de diseño y análisis de la operación de las plantas de destilación de crudos generalmente es suficiente caracterizar el crudo y sus fracciones para obtener los valores de gravedad, curvas de destilación de laboratorio, análisis para determinación de componentes livianos (metano, etano, butano, isobutano etc.) y análisis para determinación de tipos de hidrocarburo (parafinas, isoparafinas, aromáticos, resinas y asfáltenos) medios y pesados³².

De acuerdo con los objetivos de este trabajo de aplicación, las propiedades o parámetros a utilizar son la gravedad del crudo y las curvas de destilación de las fracciones del crudo Jet A y ACPM las cuales se explicaran a continuación.

La gravedad del crudo o sus fracciones es generalmente medida por la prueba estandarizada de laboratorio ASTM D 287 o la prueba equivalente ASTM D1298 y puede ser reportada como gravedad especifica SG (es la relación de las densidades del crudo y el agua medidas a 60°F) o más comúnmente como

³¹ Ibid


³² R. PERRY, Manual del Ingeniero Químico, Destilación, Vol 2, Cap 13, 1997.

gravedad API la cual está definida como: $\text{API gravedad} = 141.5 / (\text{SG } 60/60^\circ\text{F}) - 131.5$.³³

La gravedad API del agua es 10, los crudos y sus fracciones tienen valores de gravedad API en un rango de 10 a 80. Hidrocarburos livianos (n-pentano y más livianos) tienen valores de gravedad API de hasta 92.8 [4]; de acuerdo a esto entre más liviano (volátil) sea el hidrocarburo mayor es el número de gravedad API³⁴.

La volatilidad de los crudos y sus fracciones es también caracterizada en términos de una o más pruebas de destilación en laboratorio, una de estas pruebas de destilación en laboratorio es la ASTM D86 la cual aplica para fracciones como el Jet A y ACPM. Esta prueba es una destilación *batch* a nivel de laboratorio que equivale aproximadamente a una etapa de equilibrio sin reflujo excepto por el causado por la pérdidas de calor³⁵. Los equipos de laboratorio utilizados para esta prueba de destilación se muestran en la siguiente figura:

Figura 2. Equipos de laboratorio utilizados para la prueba de destilación ASTM D86



Fuente: R. PERRY, Manual del Ingeniero Químico, Destilación, Vol 2, Cap 13, 1997.

³³ Ibid

³⁴ Ibid


³⁵ Ibid

La prueba de destilación ASTM D86 se lleva a cabo a presión atmosférica y consiste en cargar una muestra de 100mL en un matraz y calentar lo suficiente para producir la primera gota de destilado en la parte final del tubo del condensador. La temperatura del vapor en este instante es registrado como el punto inicial de ebullición (PIE). El calentamiento continúa hasta que se recupera en el cilindro ubicado después del condensador el 5% del volumen de la muestra, en este momento se registra nuevamente la temperatura del vapor. Luego sucesivamente las temperaturas del vapor son registradas desde el 10% hasta el 90% del volumen de líquido recuperado de la muestra en intervalos de 10%, la temperatura del vapor cuando se recupera el 95% del volumen de la muestra también es registrada [4], esta temperatura para el caso de las especificación de la fracción del ACPM (*Diesel*) es conocida como la T95. Luego que se recupera el 95% del volumen la llama del quemador se incrementa si es necesario para alcanzar la máxima temperatura de vapor conocida como el punto final de ebullición (PFE) la cual se logra después de 3 a 5 min. El porcentaje recuperado en el cilindro es reportado como el porcentaje máximo recuperado. Cualquier residuo remanente en el matraz es reportado como porcentaje de residuo y el porcentaje perdido es reportado como la diferencia de los 100 mL de muestra entre la suma del porcentaje recuperado y porcentaje de residuo³⁶..

En la figura 3 se muestran las curvas de destilación ASTM D86 típicas para las fracciones del crudo:

³⁶ Ibid

Figura 3. Curvas de destilación ASTM D86 típicas para fracciones del petróleo



4.2. DESCRIPCIÓN UNIDAD DE DESTILACIÓN DE CRUDOS U150 SECCIÓN ATMOSFÉRICA.

La unidad de destilación de crudos U150 tiene una operación estable y sus modos de operación no implican cambios significativos. Los principales ajustes en el modo de operación se relacionan con la calidad de la dieta, tipos de crudo, gravedad API, azufre y contenido de BSW (lodos, sedimentos y agua)³⁷.

De acuerdo con los cambios de estas variables hay que hacer ajustes de presión en el sistema atmosférico, temperaturas a la salida de los hornos, ajuste en reflujos de las torres y ajustes en la operación de los desaladores³⁸.

³⁷ GRB-ECOPETROL S.A., Manual de descripción de procesos de la unidad de crudo U150 MDPU, RWD, Cap 3 - 6, 2008.

³⁸ Ibid

El flujo de carga normal por diseño a la unidad es de 38 000 BPD si se trata de un crudo Cupiagua o Cusiana que poseen una densidad entre 40 y 45°API, pero disminuye a 36 000 BPD para crudos con densidades entre 35 y 40°API como es el caso del crudo mezcla Orensa carga actual de la unidad y 32 000BPD para crudos con una gravedad entre 22 y 32 °API (Crudos Mezcla y Nafténico).

Crudo Mezclado: El crudo mezclado o la premezcla pesada es una combinación de los siguientes crudos: Vasconia, Omimex, Campos (HCT, Casabe, Payoa, Provincia, Galán, Opón), Ayacucho (Isla-6), Caño limón y LCT³⁹.

Crudo Cusiana: Es el crudo Cusiana proveniente de campos⁴⁰.

Crudo Cupiagua: Es el crudo Cupiagua o Parafínicos proveniente de campos⁴¹.

Crudo Nafténico: Es el crudo LCT (*Low Cold Temperature*-Temperatura de Fluidez Baja) proveniente del distrito de producción del centro⁴².

Crudo Mezcla Orensa: Es el crudo Cupiagua mezclado con crudos no parafínicos de menor gravedad API⁴³.

La planta genera varios tipos de productos y subproductos lo cuales se muestran a continuación:

³⁹ Ibid

⁴⁰ Ibid

⁴¹ Ibid

⁴² Ibid

⁴³ Ibid

Tabla 1. Productos U150

Producto	Torre
Nafta Virgen Liviana	T-152
Nafta Virgen Pesada	T-150
Jet A	T-150
ACPM	T-150
Asfalto	T-131

Fuente: GRB-ECOPETROL S.A., Manual de descripción de procesos de la unidad de crudo U150 MDPU, RWD, Cap 3 - 6, 2008.

Tabla 2. Subproductos U150

Subproducto	Torre
Gases	T-152 y T-150
Butanos	T-171
Gasóleo Atmosférico	T-150
Gasóleo Liviano de Vacío	T-131
Destilado Liviano/Medio	T-131
Destilado Medio/Pesado	T-131

Fuente: GRB-ECOPETROL S.A., Manual de descripción de procesos de la unidad de crudo U150 MDPU, RWD, Cap 3 - 6, 2008.

La sección atmosférica de la U150 comprende desde la bomba de carga, el primer y segundo tren de crudo, la torre preflash, el horno atmosférico y la torre atmosférica con todos sus equipos anexos.

Primer Tren de Intercambio de Calor. El crudo proveniente de los tanques de carga llega a la unidad donde es impulsado por las bombas de carga hacia el primer tren de intercambio de calor, cuyos objetivos son enfriar los gases de cima

de la T-150 y subir la temperatura del crudo para garantizar una correcta operación en el desalador⁴⁴.

Desalador. La unidad cuenta con un desalador que tiene como objetivo principal remover las impurezas que trae el crudo proveniente de los tanques. A la corriente de crudo, al salir del primer tren de intercambio de calor se le inyecta agua. El crudo precalentado entra al Desalador D-152 por la parte inferior donde se realiza el proceso de retiro del agua y sedimentos. El crudo desalado sale por la parte superior del desalador hacia el siguiente tren de intercambio de calor, para luego entrar a la torre preflash⁴⁵.

Segundo Tren de Intercambio de Calor. El crudo del desalador recorre los intercambiadores que reciben calor por parte de otras corrientes en los procesos que fluyen, con el fin de lograr la temperatura necesaria para entrar a la torre preflash⁴⁶.

Torre Preflash. El crudo recorre los intercambiadores con el fin de lograr la temperatura necesaria para conseguir que se despoje la mayor cantidad de gases y nafta que venga con el crudo en esta torre. Los gases se envían al Compresor C-245 o a las unidades de cracking y la nafta se divide en dos corrientes: una se envía como reflujo hacia la cima de la torre y la otra sale como nafta producto hacia el pool o hacia la Torre Debutanizadora T-171⁴⁷.

Horno Atmosférico. El horno atmosférico tiene como función transmitir la energía necesaria al crudo desalado para facilitar la destilación en la torre atmosférica y de esta manera recuperar productos valiosos. La carga precalentada por los

⁴⁴ GRB-ECOPETROL S.A., Manual de descripción de procesos de la unidad de crudo U150 MDPU, RWD, Cap 3 - 6, 2008.

⁴⁵ Ibid

⁴⁶ Ibid

⁴⁷ Ibid

intercambiadores fluye hacia el horno donde la temperatura se incrementa hasta alcanzar valores necesarios para la alimentación de la Torre Atmosférica T-150⁴⁸.

Torre Atmosférica. El crudo parcialmente vaporizado a través de la línea de transferencia entra a la torre en donde la parte vaporizada asciende por la torre y la parte líquida cae a los platos del fondo. La condensación de los vapores de hidrocarburo ocurre a medida que la temperatura en la torre se reduce, produciéndose corrientes laterales líquidas que se recuperan en los colectores de salida de la torre⁴⁹.

Circuito de Cima. Los gases de cima se condensan parcialmente en el lado casco de los condensadores de cima y llegan al Drum de Nafta D-150. La parte no condensada se envía hacia el Compresor de Gases C-245 o hacia las Unidades Recuperadoras de Vapores (VRU) de las Unidades Cracking. La parte que se condensó se divide en dos corrientes: la primera retorna a la torre como reflujo de cima con el fin de controlar la temperatura en esta zona y la segunda sale como nafta producto hacia tratamiento y la Torre Debutanizadora T-171/ T-252.⁵⁰

Circuito de Jet. De acuerdo con las necesidades, el mismo circuito puede ser usado tanto para queroseno como para Jet A1. Se extrae normalmente del plato colector de la torre y entra al despojador. El despojo se hace con vapor que ha sido sobrecalentado en la zona de convección del horno atmosférico. Los vapores del despojador regresan a la torre por encima del plato de extracción. El Jet A sale del fondo del despojador a enfriarse y se envía a tratamiento con soda⁵¹.

Circuito de ACPM. El ACPM se extrae normalmente del plato colector de la torre y entra al despojador. El despojo se hace con vapor que ha sido sobrecalentado en

⁴⁸ Ibid

⁴⁹ Ibid

⁵⁰ Ibid

⁵¹ Ibid

la zona de convección del horno atmosférico. Los vapores del despojador regresan a la torre por encima del plato de extracción. El ACPM producto sale por el fondo del despojador a enfriarse y se envía a los tanques de almacenamiento por la línea de alto azufre o bajo azufre según sea ACPM o ACEM. En la unidad existen las facilidades para desviar ACPM a gasóleo o para ALC⁵².

Circuito de Gasóleo Atmosférico. El gasóleo se extrae del plato colector de la torre y entra al despojador. El despojo se hace con vapor que ha sido sobrecalentado en la zona de convección del horno atmosférico. Los vapores del despojador regresan a la torre por encima del plato de extracción. El gasóleo sale por el fondo y se envía al sistema de gasóleos o combustóleo⁵³.

Circuitos de Reflujo. En la torre atmosférica hay dos circuitos externos para controlar el perfil de temperatura de la torre. El circuito de reflujo superior o medio se extrae del plato 19, se enfría y retorna sobre la zona empacada superior. El circuito de reflujo inferior se extrae del plato 12, se enfría en tres intercambiadores y retorna sobre la zona empacada media⁵⁴.

Circuito de Fondos. La fracción líquida de la carga fluye al fondo de la torre a través de los platos de despojo. En esta sección el líquido se despoja de los hidrocarburos livianos mediante vapor recalentado que se inyecta al fondo de la torre. El crudo reducido se envía al Tambor de Carga D-131 lado vacío⁵⁵.

En los siguientes esquemas se muestran las secciones (primer tren de precaliente, desalado, segundo tren precaliente, torre preflash, horno atmosférico y torre atmosférica) de la U150 lado atmosférico anteriormente descritas.

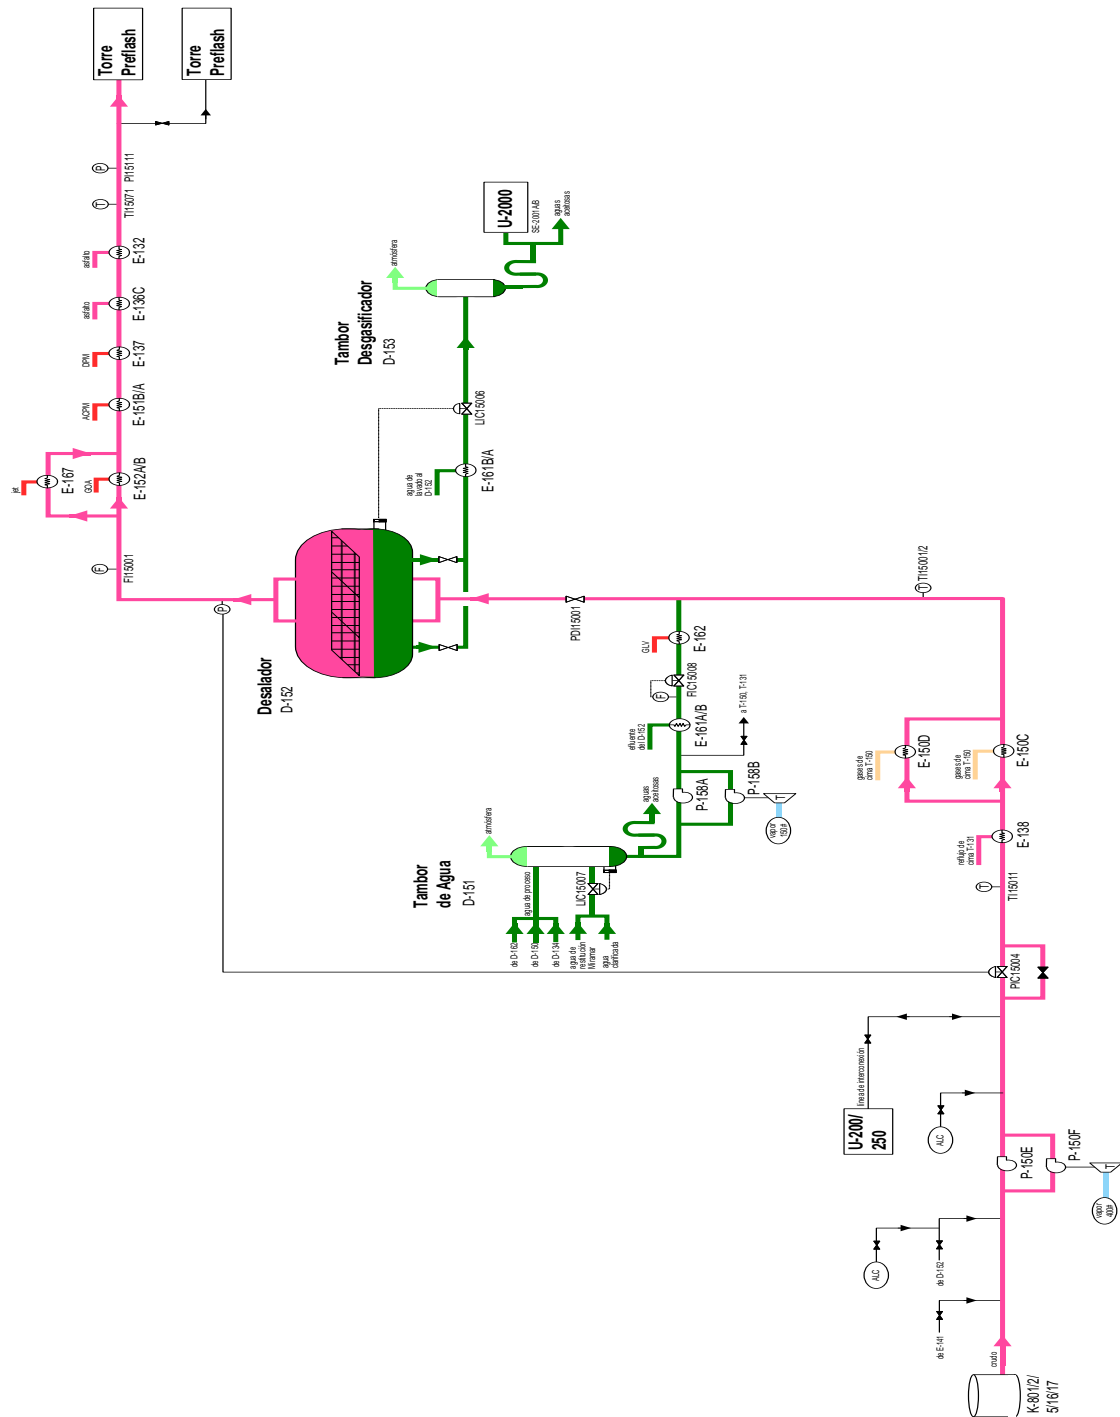
⁵² GRB-ECOPETROL S.A., Manual de descripción de procesos de la unidad de crudo U150 MDPU, RWD, Cap 3 - 6, 2008.

⁵³ Ibid

⁵⁴ Ibid

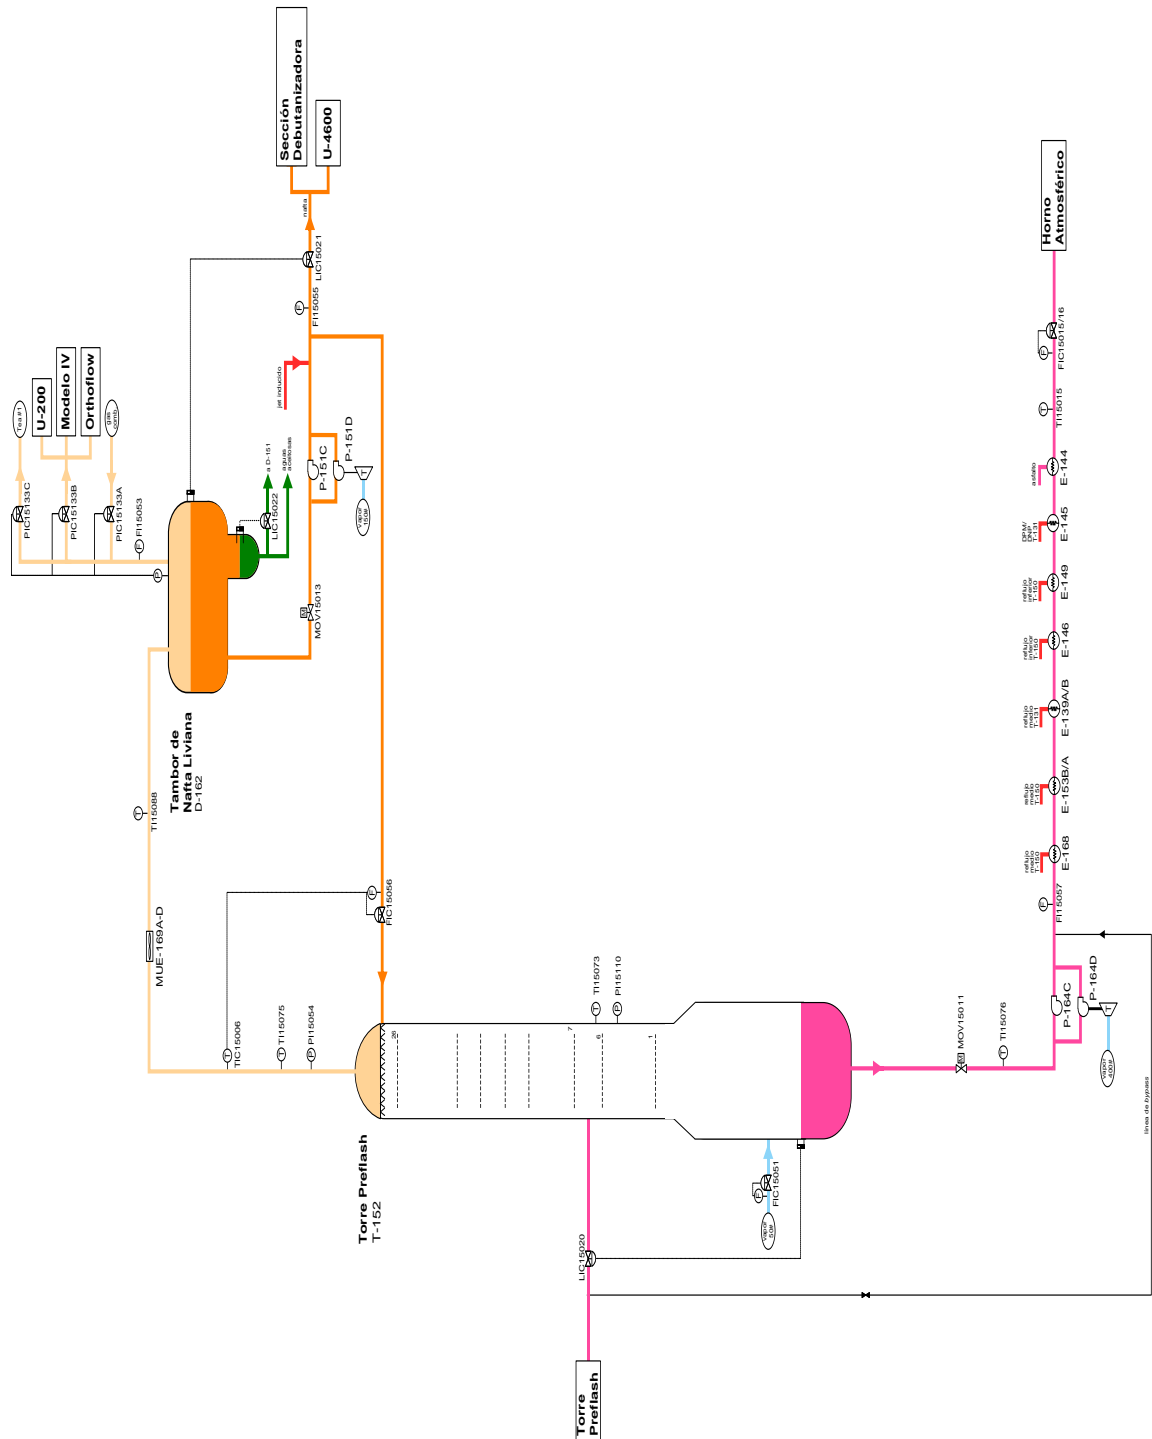
⁵⁵ Ibid

Figura 4. Diagrama de Flujo Primer Tren de Precaliente, Desalado y Segundo Tren de Precaliente U150



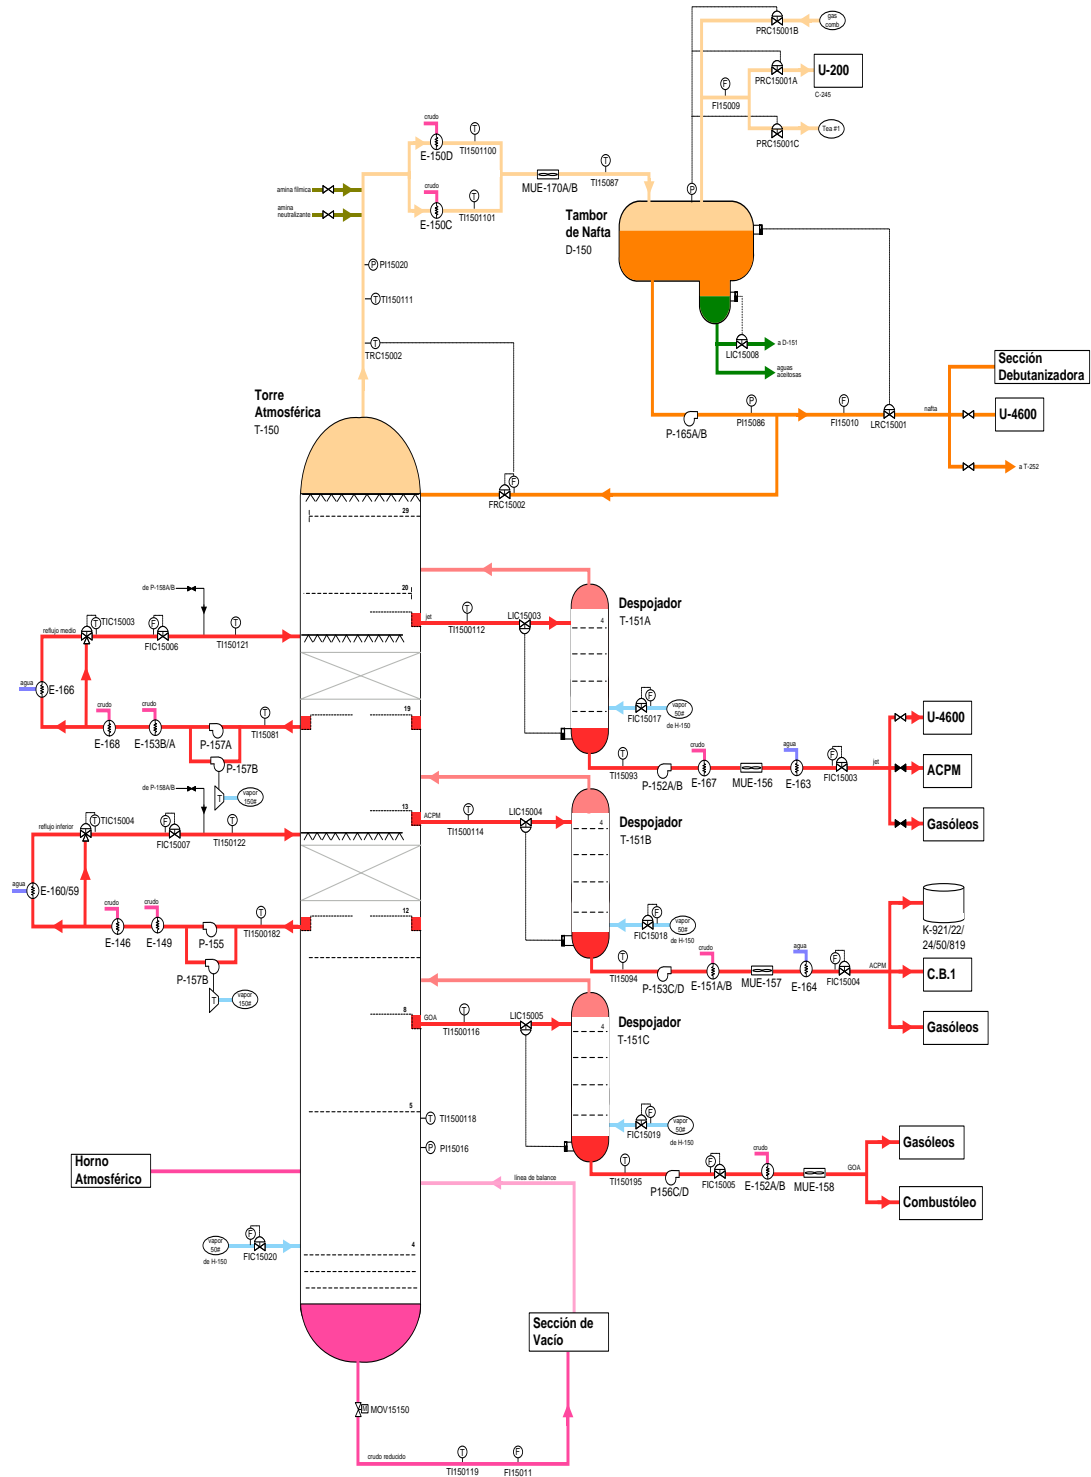
Fuente: GRB-ECOPETROL S.A., Manual de descripción de procesos de la unidad de crudo U150 MDP, RWD, Cap 3 - 6, 2008.

Figura 5. Diagrama de Flujo Torre Preflash.



Fuente: GRB-ECOPETROL S.A., Manual de descripción de procesos de la unidad de crudo U150 MDPU, RWD, Cap 3 - 6, 2008.

Figura 6. Diagrama de Flujo Torre Atmosférica.



Fuente: GRB-ECOPETROL S.A., Manual de descripción de procesos de la unidad de crudo U150 MDPU, RWD, Cap 3 - 6, 2008.

En la siguiente tabla se muestran las principales variables de operación de la torre fraccionadora T150 de la U150, las cuales se consideraron como alternativas para ser utilizadas como variables de entrada al modelo para la predicción del PFE del Jet A y T95 del ACPM.

Tabla 3. Tabla de control torre fraccionadora T150

Variables de Operación	Intervalo de Operación	Objetivo de Control/Consecuencias de Desviación (Bajo y Alto)
<i>TI-15110</i> <i>Temperatura de Salida H-150</i>	630-720 °F	Indica la temperatura combinada de proceso a la salida de los serpentines de crudo del Horno Atmosférico H-150. Alta Temperatura: Daños mecánicos en el horno por sobre calentamiento de los tubos del horno, sobre presión en los sistemas y evaporación excesiva al entrar a la sección de torre atmosférica. Baja Temperatura: Arrastre de fracciones con el crudo reducido, congestión en Torre Atmosférica T-150. Separación deficiente en la columna.
<i>TRC-15002</i> <i>Control de Temperatura de Cima T-150</i>	265-320 °F	Controla la temperatura de cima de la Torre Atmosférica T-150, ajustando el controlador de reflujo de cima FRC15002, con el cual trabaja en cascada. Alta Temperatura: Alto PFE de la nafta pesada; menor producción de Jet A1; presionamiento de la torre. Baja Temperatura: Bajo PIE de la nafta pesada; bajo rendimiento de nafta; mayor producción de Jet A1, pero con mayor contenido de livianos.
<i>PI-15020</i> <i>Presión de Cima T-150</i>	10-14 psig	Mide la presión de vapores de salida de la cima de la Torre Atmosférica T-150. Alta Presión: Alta presión; bajo despojo; disturbio en sistema de tea N° 1. Baja Presión: Alto despojo de nafta; baja producción de Jet; alta concentración de pesados en los productos.

Variables de Operación	Intervalo de Operación	Objetivo de Control/Consecuencias de Desviación (Bajo y Alto)
<i>PIC-15001</i> Control de Presión D-150	9-15 psig	Controla la presión en el D-150, actuando sobre tres válvulas en rango dividido: PIC15001B (que recibe gas combustible), PIC15001C (que envía exceso de gas a la tea N° 1) y PIC15001A (que envía gas a la URC). Alta Presión: Alta presión; bajo despojo; disturbio en sistema de tea N° 1. Baja Presión: Alto despojo de nafta; baja producción de Jet; alta concentración de pesados en los productos.
<i>FRC-15002</i> Control de Reflujo de Cima	8000-17400 bpd	Controla el reflujo de cima de la Torre Atmosférica T-150, basado en la señal provista por el controlador de temperatura de cima TRC15002, con el cual trabaja en cascada. Alto Flujo: Posible inundación de la torre. Bajo perfil de temperatura de la T-150 con disminución del PIE del Jet. Bajo Flujo: Daño del color de la nafta; alta temperatura de cima de la T-150, alto PFE de la nafta pesada. Posible daño del equipo de bombeo por bajo flujo.
<i>FI-15010</i> Indicador de Flujo de Nafta	1000-4000 bpd	Indica el flujo de nafta pesada al pool. Alto Flujo: Alta vaporización, alta temperatura de cima de la T-150. Alto nivel en tambor de nafta. Bajo Flujo: Menor Vaporización, posible daño del equipo rotativo. Alta presión en cabezal de naftas y bajo nivel de nafta por temperatura de cima muy baja.
<i>TI-150181</i> Temperatura Salida Reflujo Medio T-150	530-370 °F	Indica la temperatura de salida del reflujo medio de la Torre Atmosférica T-150. Alta Temperatura: Aumento de perfil de temperaturas en toda la torre, causando composiciones más pesadas en productos; aumento en carga al sistema de condensación de cima con posibilidad de exceder su capacidad. Baja Temperatura: Disminución de perfil de temperaturas en toda la torre, causando composiciones más livianas en productos.

Variables de Operación	Intervalo de Operación	Objetivo de Control/Consecuencias de Desviación (Bajo y Alto)
<p>TIC-15003 Temperatura Zona Media T-150</p>	350-400 °F	<p>Controla la cantidad de reflujo medio que pasa por el Enfriador E-166, ajustando la válvula de desvío (bypass) alrededor del mismo basado en lecturas de temperatura proporcionada por el indicador TI15003.</p> <p>Alta Temperatura: Insuficiente flujo a través de E-166, causando insuficiente enfriamiento en corriente de reflujo medio, mayor temperatura de vapores hacia la cima.</p> <p>Baja Temperatura: Excesivo flujo a través de E-166, causando exceso de enfriamiento en corriente de reflujo medio (superior), menor perfil de temperatura en la torre, causando composiciones más livianas en productos.</p>
<p>FIC-15006 Flujo de Reflujo Medio T-150</p>	8400-29600 bpd	<p>Controla el flujo del reflujo medio de la Torre Atmosférica T-150.</p> <p>Alto Flujo: Inundación de la Torre y baja temperatura de esta zona de la torre.</p> <p>Bajo Flujo: Daño de la bomba; alta temperatura de la zona y mayor despojo.</p>
<p>TI-150121 Temperatura de Entrada del Reflujo Medio T-150</p>	350-400 °F	<p>Indica la temperatura de entrada del reflujo medio a la Torre Atmosférica T-150.</p> <p>Alta Temperatura: Aumento de perfil de temperaturas en toda la torre, causando composiciones más pesadas en productos; aumento en carga al sistema de condensación de cima, con posibilidad de exceder su capacidad.</p> <p>Baja Temperatura: Disminución de perfil de temperaturas en toda la torre, causando composiciones más livianas en productos.</p>

Variables de Operación	Intervalo de Operación	Objetivo de Control/Consecuencias de Desviación (Bajo y Alto)
<i>TI-150082</i> Temperatura Salida Reflujo Inferior T-150	650-510 °F	Indica la temperatura de salida del reflujo medio de la Torre Atmosférica T-150. Alta Temperatura: Aumento de perfil de temperaturas en toda la torre, causando composiciones más pesadas en productos y aumento en carga al sistema de condensación de cima, con posibilidad de exceder su capacidad. Baja Temperatura: Disminución de perfil de temperaturas en toda la torre, causando composiciones más livianas en productos.
<i>TIC-15004</i> Controlador Temperatura de Reflujo Inferior T-150	530-560 °F	Controla la cantidad de reflujo inferior que pasa por el Intercambiador E-160/159, ajustando la válvula de desvío (bypass) alrededor del mismo basado en lecturas de temperatura proporcionada por el indicador TI15004. Alta Temperatura: Aumento de perfil de temperaturas en toda la torre, causando composiciones más pesadas en productos; aumento en carga al sistema de condensación de reflujo medio, con posibilidad de exceder su capacidad. Baja Temperatura: Disminución de perfil de temperaturas en toda la torre, causando composiciones más livianas en productos, disminuye la recuperación de ACPM y Jet.
<i>FIC-15007</i> Control de Flujo del Reflujo Inferior	4400-12000 bpd	Controla el reflujo inferior a la Torre Atmosférica T-150. Alto Flujo: Inundación de la Torre; baja temperatura de esta zona de la torre. Bajo Flujo: Daño de la bomba; alta temperatura de la zona; mayor despojo.

Variables de Operación	Intervalo de Operación	Objetivo de Control/Consecuencias de Desviación (Bajo y Alto)
<p>TI-150122 Temperatura de Entrada del Reflujo Inferior T-150</p>	530-550 °F	<p>Indica la temperatura de salida del reflujo inferior de la Torre Atmosférica T-150.</p> <p>Alta Temperatura: Aumento de perfil de temperaturas en toda la torre, causando composiciones más pesadas en productos; aumento en carga al sistema de condensación de cima y al reflujo medio, con posibilidad de exceder su capacidad.</p> <p>Baja Temperatura: Disminución de perfil de temperaturas en toda la torre, causando composiciones más livianas en productos.</p>
<p>TI-1500112 Temperatura Salida Jet T-151A</p>	415-430 °F	<p>Mide la temperatura de salida de Jet A1 de la Torre Atmosférica T-150 a la Despojadora de Jet T-151A.</p> <p>Alta Temperatura: Alto PFE del producto, posiblemente se salga de especificación por destilación.</p> <p>Baja Temperatura: Bajo PFE del producto, posiblemente se salga de especificación por chispa y destilación.</p>
<p>FIC-15017 Vapor de Despojo T-151A</p>	700-1500 lb/h	<p>Controla el flujo de vapor de despojo a la Torre Despojadora T-151A.</p> <p>Alto Flujo: Gasto excesivo de vapor, incrementando carga a sistema de condensación de cima de Torre Atmosférica T-150.</p> <p>Bajo Flujo: Insuficiente despojo de producto jet. Baja chispa del Jet.</p>
<p>FIC-15003 Producción Jet</p>	1950-7200 bpd	<p>Controla la producción de jet de la Torre Despojadora de Jet T-151A, ajustando el flujo a través del Ventilador E-156 y del Enfriador E-163.</p> <p>Alto Flujo: Mayor PFE del producto; bajo nivel de la despojadora.</p> <p>Bajo Flujo: Menor producción; inundación en la despojadora.</p>
<p>TI-1500114 Temperatura de Salida ACPM T-151B</p>	530-560 °F	<p>Mide la temperatura de salida del gasóleo de la Torre Atmosférica T-150 a la Torre Despojadora de ACPM T-151B. Indica la calidad del producto.</p> <p>Alta Temperatura: Alto PFE del producto, posiblemente se salga de especificación por destilación.</p> <p>Baja Temperatura: Bajo PFE del producto, posiblemente se salga de especificación por chispa y destilación.</p>

Variables de Operación	de	Intervalo de Operación	de	Objetivo de Control/Consecuencias de Desviación (Bajo y Alto)
<i>FIC-15018</i> Vapor Despojo T-151B	de	500-2000 lb/h		Controla el flujo de vapor de despojo a la Torre Despojadora de ACPM T-151B. Alto Flujo: Gasto excesivo de vapor, incrementando carga a sistema de condensación de cima de Torre Atmosférica T-150. Bajo Flujo: Insuficiente despojo de producto ACPM. Bajo punto de chispa del producto.
<i>FIC-15019</i> Vapor Despojo T-151C	de	500-2000 lb/h		Controla el flujo de vapor de despojo a la Torre Despojadora T-151C. Alto Flujo: Gasto excesivo de vapor, incrementando carga a sistema de condensación de cima de Torre Atmosférica T-150. Bajo Flujo: Insuficiente despojo de producto gasóleo.
<i>FIC-15004</i> Producción ACPM		3300-8700 bpd		Controla la producción de ACPM de la Torre Despojadora de ACPM T-151B. Alto Flujo: Mayor PFE del producto; bajo nivel de la despojadora. Bajo Flujo: Menor producción; inundación en la despojadora.
<i>FIC-15020</i> Vapor Despojo T-150		500-4000 lb/h		Controla el flujo de vapor de despojo que se inyecta al fondo de la Torre Atmosférica T-150. Alto Flujo: Gasto excesivo de vapor, incrementando carga a sistema de condensación de cima de Torre Atmosférica T-150. Posible daño de los internos de la torre. Bajo Flujo: Insuficiente despojo de crudo, causando problemas en Sección de Vacío debido a exceso de livianos. Menor producción de productos valiosos en la T-150.

Fuente: GRB-ECOPETROL S.A., Manual de descripción de procesos de la unidad de crudo U150 MDPU, RWD, Cap 3 - 6, 2008.

4.3. SOFT SENSOR.

Los *soft sensor* son una herramienta valiosa para muchos campos de aplicación industrial, incluyendo refinerías, plantas químicas, cementeras, plantas de energía, industria del papel, procesamiento de alimentos, plantas nucleares, monitoreo de polución urbana e industrial y estos son apenas algunos ejemplos. Estos son usados para resolver diferentes tipos de problemas tales como sistemas de medición sin respaldo, análisis que pasa si, predicción en tiempo real para control de plantas, validación de mediciones, y estrategia para diagnóstico de fallas⁵⁶.

En las plantas de proceso como las refinerías de crudo la mayoría de las variables de operación son medidas por sensores en línea, pero hay variables de proceso importantes que dan información sobre la calidad del producto, que no pueden ser medidas por un sensor o las mediciones son muy caras o no son lo suficiente confiables para ser usadas. Los valores de esas variables difíciles de medir son a menudo determinadas por análisis de laboratorio de muestras tomadas del proceso⁵⁷.

La exactitud y la frecuencia de muestreo de los sensores en línea son los factores más importantes para un monitoreo y control satisfactorio. Sin embargo, algunas veces la información obtenida del sensor puede ser inútil o incluso completamente ausente por varias razones: fallas de los sensores, falla del sistema de adquisición de datos, retiro del sensor para mantenimiento o reemplazo, y sensores con muy baja frecuencia de muestreo como por ejemplo cromatografías de gas, destilación de fracciones del crudo, y analizadores NIR. Esto puede afectar negativamente el monitoreo y control que puede resultar en incrementos de los costos de

⁵⁶ L. FORTUNA, S. GRAZIANI, A. RIZZO, and M. XIBILIA, *Soft sensors for monitoring and control of industrial processes*, Springer Verlag, 2007.

⁵⁷ D. SLISKOVIC, R. GRBIC, and Z. HOCENSKI, *Methods for Plant Data-Based Process Modeling in Soft-Sensor Development*, *Automatica* 52, Vol 4, págs 306-318, 2011.

producción, productos fuera de especificación o incluso situaciones peligrosas para el personal de planta y el ambiente⁵⁸.

Es por esto que los *soft sensor* son comúnmente utilizados para mejorar la confiabilidad del sistema, el control y monitoreo del proceso. Los *soft sensor* se basan en un modelo matemático que conecta variables de fácil medición como flujos, temperaturas y presiones con variables de salida de difícil medición como por ejemplo la viscosidad, el PFE o la T95⁵⁹.

Modelamiento basado en datos de planta.

En la práctica los modelos generalmente no están disponibles así que tienen que ser construidos, hay dos maneras de hacerlo una por modelamiento teórico (principios físicos y químicos) o modelamiento empírico basado en datos⁶⁰.

El modelamiento teórico se basa en ecuaciones diferenciales que describen principios físicos y químicos. Teniendo en cuenta que los procesos industriales son complejos los modelos teóricos son imprácticos y consumen mucho tiempo. Por otro lado el modelamiento empírico basado en datos, es usado cuando no hay suficiente conocimiento previo del proceso. Este tipo de modelamiento genera modelos simples y mejores descripciones de las relaciones entre las variables de entrada y salida que los modelos teóricos y también pueden ser aplicados para diferentes tipos de modelos⁶¹.

En el modelamiento basado en datos esto últimos se obtienen del proceso. Hay dos maneras en que los datos pueden ser obtenidos: a través de un diseño de

⁵⁸ Ibid

⁵⁹ Ibid

⁶⁰ Ibid

⁶¹ Ibid

experimentos especial (datos experimentales) o a través de la operación normal de la planta (datos de planta, datos históricos)⁶² .

La ventaja de obtener los datos a través de un diseño de experimentos es que si la experimentación es cuidadosamente planeada, los datos pueden ser muy informativos ya que todos los modos operación del proceso pueden ser activados y la presencia de disturbios y errores en los datos pueden ser reducidos a lo más mínimo posible. Sin embargo en muchas ocasiones realizar este tipo experimentos en plantas no es permitido o es muy costoso⁶³].

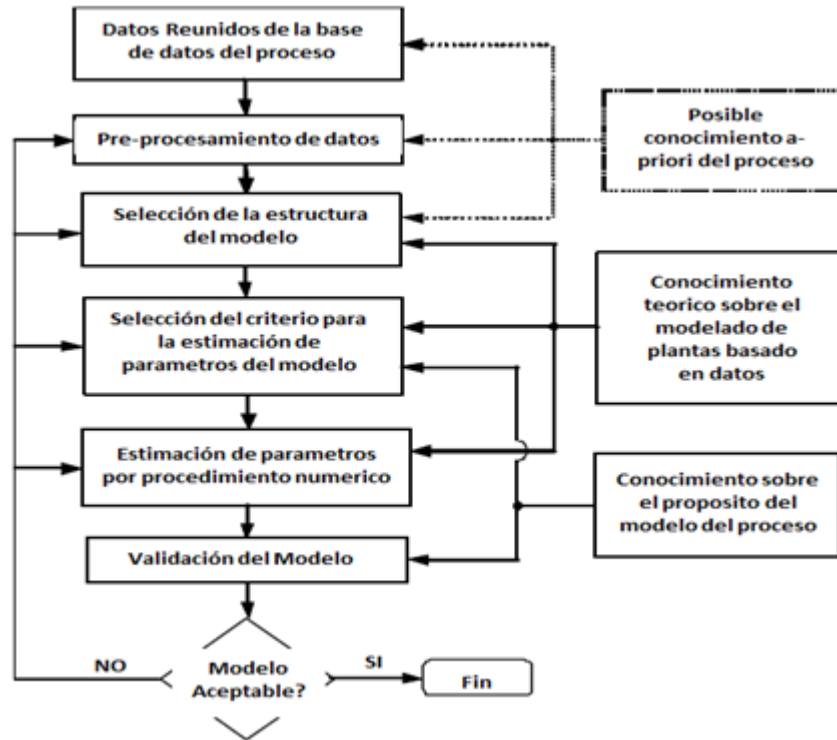
Las plantas modernas industriales están generalmente equipadas con un amplio número de sensores los cuales miden diferentes números de variables de proceso. Esos datos medidos a través de un par de años y acumulados en la base de datos de proceso, pueden ser utilizados como fuente de información para construir los modelos⁶⁴]. El procedimiento de modelamiento basado en datos de proceso se muestra en la **figura 7**

⁶² D. SLISKOVIC, R. GRBIC, and Z. HOCENSKI, Methods for Plant Data-Based Process Modeling in Soft-Sensor Development, Automatica 52, Vol 4, págs 306-318, 2011.

⁶³ Ibid

⁶⁴ Ibid

Figura 7. Diagrama de Flujo Procedimiento de Modelado Basado en Datos de Planta.



Fuente: D. SLISKOVIC, R. GRBIC, and Z. HOCENSKI, Methods for Plant Data-Based Process Modeling in Soft- Sensor Development, Automatica 52, Vol 4, págs 306-318, 2011.

Cuando los datos son adquiridos en su forma primaria, estos a menudo tienen muchas inconsistencias como resultado de diferentes disturbios, malos funcionamientos, degradaciones y errores en los sensores y el sistema de adquisición de datos. Además solo algunas de las variables medidas son importantes para el procedimiento de modelización. Por lo tanto el pre-procesamiento de datos el cual incluye selección de variables, eliminación de datos de ruido, detección de “outliers” y reemplazo de datos faltantes es una parte importante para el procedimiento de modelado. Después de esto, es necesario buscar la estructura apropiada del modelo. El siguiente paso es la definición de los

criterios para la estimación de los parámetros del modelo seguido por su estimación usando un procedimiento numérico apropiado. Si el modelo construido satisface los requerimientos, el procedimiento de modelado finaliza. Sin embargo, esto es una situación inusual en la práctica y el modelamiento es generalmente alcanzado después de varias iteraciones. La selección de la apropiada estructura del modelo y los criterios para estimación de los parámetros no son tareas triviales y requieren especial atención, ya que tienen gran impacto en toda la calidad del *soft sensor*⁶⁵.

Pre-procesamiento de Datos (selección de datos y filtrado)

El primer paso en el proceso de modelamiento para el diseño de un *soft sensor* es el análisis crítico de la información disponible de la base de datos de la planta con el fin de seleccionar las variables de influencia candidatas y los eventos que llevan información sobre sistemas dinámicos, correspondiente al objetivo previsto del *soft sensor*. Esta tarea, por supuesto requiere de la cooperación de un diseñador de *soft sensor* y experto en plantas de proceso en forma de reuniones y entrevistas. En todo caso, una regla del dedo gordo es que una variable candidata y/o registro de dato puede ser eliminado durante el proceso de diseño, por lo que es mejor ser conservador durante la fase inicial. De hecho si una variable que lleva información útil es eliminada durante esta fase preliminar una iteración fallida puede ocurrir con consecuencias de pérdidas de tiempo y recursos.⁶⁶

La recolección de datos es una cuestión fundamental y el diseñador del modelo podría seleccionar datos que represente todo el sistema dinámico, esto es posible mediante la ejecución de experimentos adecuados en la planta. Disturbios de alta frecuencia podrán ser también removidos⁶⁷.

⁶⁵ Ibid

⁶⁶ L. FORTUNA, S. GRAZIANI, A. RIZZO, and M. XIBILIA, *Soft sensors for monitoring and control of industrial processes*, Springer Verlag, 2007.

⁶⁷ Ibid

Por otra parte, una cuidadosa investigación de los datos disponibles es requerida con el fin de detectar ya sea datos erróneos u atípicos (*outliers*), debido a las fallas en medición o transmisión de dispositivos o inusuales disturbios. En particular como en cualquier procedimiento impulsado por datos, *outliers* pueden tener un inesperado efecto en la calidad del modelo⁶⁸.

Los datos recolectados de la base de datos de variables de una planta son generalmente corrompidos por la presencia de *outliers*, datos inconsistentes con la mayoría de datos recopilados, que pueden afectar significativamente el desempeño del diseño del *soft sensor* a través de datos. Se debe tener cuidado cuando se aplica la definición dada anteriormente: Los datos inusuales pueden representar la dinámica que es poco frecuente pero importante. Por lo tanto después que cualquier procedimiento automático ha sugerido una lista de *outliers*, un cuidadoso filtrado de los *outliers* candidatos deberá ser realizado con la ayuda de un experto de la planta de proceso para evitar remover información valiosa. El filtrado de datos reduce el riesgo de enmascarar *outliers* es decir cuando un *outliers* es clasificado como una muestra normal, y el inventar un *outliers* es decir cuando una muestra válida es clasificada como un dato atípico⁶⁹.

Los datos atípicos pueden aparecer aislados o en grupos, incluso con una regularidad periódica. Los datos atípicos son generalmente interpolados, pero la interpolación no tiene sentido cuando un grupo de datos atípicos son detectados. En cada caso, los datos atípicos necesitan ser removidos y el dato original deberá ser dividido en dos bloques para mantener la secuencia lógica de tiempo entre los datos, lo cual es necesario para identificar correctamente la dinámica del modelo. Por supuesto, este no es el caso para modelos estáticos, los cuales solo requieren que las muestras correspondientes a las variables restantes sean removidas⁷⁰.

⁶⁸ Ibid

⁶⁹ Ibid

⁷⁰ Ibid

El primer paso hacia el filtrado de datos atípicos consiste en la identificación de datos automáticamente etiquetados con algún tipo de etiqueta de invalidación (*NaN, Data_not_Valid, and Out_of_Range*). Después de que este procedimiento se ha sido realizado, algún tipo de procedimiento de detección puede ser aplicado.

Aunque no existe un criterio universalmente aceptado, existe un número de estrategias que pueden ser empleadas. En particular, los siguientes criterios de detección de datos atípicos pueden ser utilizados⁷¹.

- *3 sigma regla editada (3 sigma edit rule)*
- *Parámetros de Jolliffe (Jolliffe Parameters)*
- *Análisis de residuos de una regresión lineal (residual analysis of linear regression)*

En la 3 sigma regla editada, la distancia normalizada, d_i , de cada muestra de la media estimada se calcula:

$$d_i = (x_i - \text{mean}_x) / \text{sigma}_x^{72}$$

Se asume que los datos siguen una distribución normal, así que la probabilidad que el valor absoluto de d_i es mayor que 3 es de alrededor 0.27% y una observación x_i es considerada un dato atípico cuando el valor absoluto de d_i es mayor que este límite.⁷³

Para reducir la influencia de múltiples datos atípicos en la estimación de la media y la desviación estándar de la variable, estas pueden ser reemplazadas con la

⁷¹L. FORTUNA, S. GRAZIANI, A. RIZZO, and M. XIBILIA, *Soft sensors for monitoring and control of industrial processes*, Springer Verlag, 2007.

⁷² Ibid

⁷³ Ibid

desviación media absoluta (MAD). La 3 sigma regla editada con un escalamiento robusto es comúnmente llamada como el identificador *Hampel*⁷⁴⁷⁵.

El método de Jolliffe se basa en el uso de los siguientes tres parámetros llamados d_{1i}^2 , d_{2i}^2 , d_{3i}^2 calculados sobre las variables z , obtenidas aplicando ya sea el análisis de componente principal (PCA) o proyección de las estructuras latentes (PLS) para las variables del modelo. Los parámetros se calculan de la siguiente manera⁷⁶:

$$\begin{aligned}
 d_{1i}^2 &= \sum_{k=p-q+1}^p z_{ik}^2 \\
 d_{2i}^2 &= \sum_{k=p-q+1}^p \frac{z_{ik}^2}{l_k} \\
 d_{3i}^2 &= \sum_{k=p-q+1}^p z_{ik}^2 l_k
 \end{aligned}
 \quad \text{Ecuación (1)}$$

Dónde: el índice i se refiere la i th muestra de la variable proyectada considerada;
 p es el número de entradas;

q es el numero principal de componentes (o variables latentes) cuya varianza es menor que las demás.

z_{ik} es la i th muestra de la k th componente principal (o variable latente);

l_k es la varianza de la k th componente.

⁷⁴ L. FORTUNA, S. GRAZIANI, A. RIZZO, and M. XIBILIA, Soft sensors for monitoring and control of industrial processes, Springer Verlag, 2007.

⁷⁵ Ibid

⁷⁶ Ibid

La estadística en las ecuaciones ha sido introducida para detectar observaciones que no son conformes con la estructura de correlación de los datos. El parámetro d_{3i}^2 fue introducido para detectar observaciones que inflan la varianza del conjunto de datos⁷⁷.

Limites adecuados para cualquiera de los parámetros introducidos anteriormente pueden utilizarse como criterios para la detección de valores atípicos. PCA y PLS pueden también ser utilizados directamente para detectar valores atípicos graficando el primer componente vs el segundo buscando los datos que quedan afuera de una región específica de la gráfica⁷⁸.

Una técnica final considerada aquí es el análisis residual de correlación lineal. Esta se basa en usar una regresión múltiple lineal entre las variables dependientes e independientes de la siguiente forma⁷⁹:

$$y = X \beta + \varepsilon \text{ Ecuación (2)}$$

Dónde:

y es el vector de los datos de salida del sistema.

X es una matriz de datos recopilados de variables de entrada.

β es el vector de parámetros.

ε es el vector de residuos.

El procedimiento requiere la aplicación del método de mínimos cuadrados para obtener una estimación de β

$$\beta = (X^T X)^{-1} X^T y \text{ Ecuación (3)}$$

⁷⁷ L. FORTUNA, S. GRAZIANI, A. RIZZO, and M. XIBILIA, Soft sensors for monitoring and control of industrial processes, Springer Verlag, 2007.

⁷⁸ Ibid

⁷⁹ Ibid

De esta manera la salida estimada es:


$$y = X\beta \text{ Ecuación (4)}$$

Y el modelo residual puede ser calculado como

$$r = y - \hat{y} \text{ [15] Ecuación (5)}$$

Los residuos se grafican juntos con un intervalo de confianza de 95% (o cualquier otro intervalo apropiado). Datos cuyo intervalo de confianza no cruza el cero en el eje x son considerados datos atípicos⁸⁰.

Figura 8. Ejemplo de datos atípicos detectados usando la técnica de regresión lineal



Fuente: L. FORTUNA, S. GRAZIANI, A. RIZZO, and M. XIBILIA, Soft sensors for monitoring and control of industrial processes, Springer Verlag, 2007.

⁸⁰ Ibid

Hay que señalar que los métodos para buscar datos atípicos son modelos simples (solo modelos estáticos se consideran para el caso de regresión lineal) entre entradas y salidas, que sugieren como datos atípicos todos los datos que no se ajustan al modelo usado con un apropiado criterio. Esto implica que la información obtenida necesita ser considerada con cuidado. De hecho, en ocasiones varios algoritmos tienden a etiquetar datos atípicos siempre que no se ajusten al modelo aproximado utilizado. Esto puede llevar a eliminar información que puede ser relevante para explicar el comportamiento dinámico del sistema, afectando de esta manera el resultado final y el diseño del *soft sensor*⁸¹.

La elección final de los datos que serán considerados datos atípicos debe ser realizada por un operador humano con la ayuda de expertos⁸².

Construcción del Modelo (selección de la estructura y criterio para estimación de parámetros del modelo)

Los datos medidos, adquiridos de la base de datos de proceso de la planta, después del paso de pre procesamiento pueden ser representados como m variables de entrada recogidas en la matriz $X \in R^{n \times m}$ y el vector de la variable de salida $y \in R^{n \times 1}$ donde n es el número de muestras disponibles. La construcción de modelos basados en datos de proceso es de hecho la búsqueda de una función de aproximación $f_m : R^m \rightarrow R$ la cual aproxima la dependencia funcional natural desconocida de la variable de proceso de salida con las variables de entrada seleccionadas. Una función con una matriz de dimensión finita de parámetros es comúnmente usada como función de aproximación por lo que el modelo puede ser representado así⁸³:

⁸¹ L. FORTUNA, S. GRAZIANI, A. RIZZO, and M. XIBILIA, *Soft sensors for monitoring and control of industrial processes*, Springer Verlag, 2007.

⁸² Ibid

⁸³ D. SLISKOVIC, R. GRBIC, and Z. HOCENSKI, *Methods for Plant Data-Based Process Modeling in Soft-Sensor Development*, *Automatica* 52, Vol 4, págs 306-318, 2011.

$$\hat{y} = f_m(x, \theta) \quad \text{Ecuación (6)}$$

Donde $x \in R^{1 \times m}$ es una muestra de las variables de entrada, Θ el vector de parámetros de la función de aproximación f_m y \hat{y} es la salida del modelo. Desde el punto de vista matemático, la búsqueda de la función de aproximación a partir de los datos disponibles es un problema mal planteado ya que hay un número infinito de posibles funciones de aproximación. La característica más importante de un *soft sensor* es su capacidad de predicción. Por lo tanto, modelos que generalicen bien serán escogidos. Generalmente, no hay un conocimiento previo sobre el proceso, lo cual no podrá ser usado en la estructuración del modelo así que una estructura general del modelo es usada. Para la función de aproximación, se usa una función que es la suma de muchas funciones⁸⁴:

$$f_m(x, \theta) = \sum_{k=1}^K v_k(x, \theta_k) \quad \text{Ecuación (7)}$$

Donde v es la función base y K es el número de funciones base. La estructuración del modelo es por lo tanto reducida a la selección del tipo de las funciones base y dimensión del modelo. Escoger la dimensión óptima del modelo juega un papel importante en capacidad de predicción del modelo⁸⁵.

Para la búsqueda de la estructura del modelo y sus parámetros, Θ tienen que ser determinadas del conjunto de datos limitados. En la construcción del modelo de predicción, los parámetros generalmente son determinados por regresión, en la cual todos los parámetros del modelo son estimados basados en la minimización del error de salida de aproximación. Los datos de planta tienen características indeseables las cuales hacen ineficientes las técnicas clásicas de regresión en la estimación de los parámetros del modelo óptimo: el espacio de entrada es

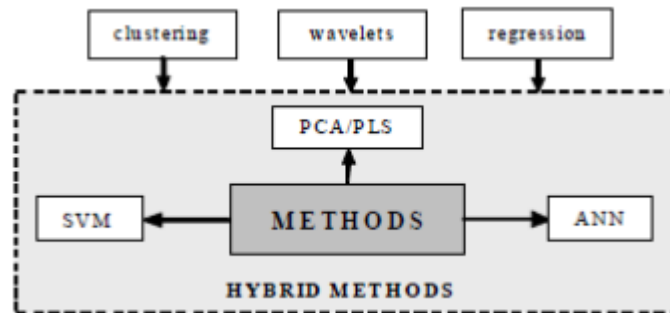
⁸⁴ Ibid

⁸⁵ Ibid

altamente dimensional, el espacio de entrada es altamente correlacionado y presencia de diferentes errores y disturbios⁸⁶.

Hay una gran cantidad de diferentes métodos (ver figura 9) de modelización que pueden ser usados para construir un modelo de proceso a partir de un conjunto de de datos de planta. Los métodos de modelización de diferentes campos que generalmente se usan para desarrollar *soft sensor son*: quimiometria, estadística e inteligencia artificial (redes neuronales artificiales)⁸⁷.]

Figura 9. Métodos de modelado usados para desarrollos de soft sensor.



Fuente: D. SLISKOVIC, R. GRBIC, and Z. HOCENSKI, Methods for Plant Data-Based Process Modeling in Soft-Sensor Development, Automatica 52, Vol 4, págs 306-318, 2011.

Métodos Estadísticos Multivariados

Estos métodos que fueron desarrollados en el campo del análisis estadístico multivariable, se usan ampliamente en el modelado basado en datos de planta para mejorar el modelado por regresión lineal⁸⁸.

⁸⁶ D. SLISKOVIC, R. GRBIC, and Z. HOCENSKI, Methods for Plant Data-Based Process Modeling in Soft-Sensor Development, Automatica 52, Vol 4, págs 306-318, 2011

⁸⁷ Ibid

⁸⁸ Ibid

El análisis de componentes principales (PCA, según sus iniciales en inglés), es a menudo usado como un método de construcción de modelos para *soft sensor*. Básicamente este método es una proyección lineal del espacio original de entrada. Las direcciones de proyección α_j (también llamadas pesos) son obtenidas por la maximización de las variaciones en el espacio de entrada⁸⁹.

$$\max_{\alpha_j} [\text{var} (X_{\alpha_j})] \quad \text{Ecuación (8)}$$

Donde la matriz X puede ser descompuesta como sigue:

$$X = \hat{X} + E = ZA^T + E \quad \text{Ecuación (9)}$$

Donde Z es una matriz ortogonal, A es una matriz ortonormal (matriz de pesos) que contienen las direcciones de las proyecciones α_j (a menudo llamadas componentes principales – PC_S), E representa variaciones no modeladas (residuos) y j representa el número variables ocultas⁹⁰.

Si el *soft sensor* es utilizado para predicción en línea de una variable de difícil medición, entonces la regresión lineal múltiple (MLR) es generalmente realizada sobre las variables ocultas o latentes con el objetivo de obtener los parámetros del modelo β . En este caso el modelo es llamado regresión del componente principal con sus siglas en inglés (PCR) y puede ser escrito así⁹¹:

$$\hat{y} = \sum_{j=1}^J \beta_j \sum_{i=1}^m \alpha_{ij} x_i \quad \text{Ecuación (10)}$$

⁸⁹ D. SLISKOVIĆ, R. GRBIC, and Z. HOCENSKI, Methods for Plant Data-Based Process Modeling in Soft-Sensor Development, Automatica 52, Vol 4, págs 306-318, 2011

⁹⁰ Ibid

⁹¹ Ibid

Las desventajas del PCA es la inhabilidad para modelar relaciones no lineales y el modelo algunas veces puede tener malas propiedades de predicción porque la relación de las entradas y salidas no se toman en consideración cuando los parámetros (las direcciones de la proyección o pesos) son determinados. Para superar esta última limitación, el método de mínimos cuadrados parciales (PLS según sus iniciales en inglés), puede ser usado. El PLS presenta una importante mejora sobre el método PCA cuando éste es usado en la construcción de un modelo de predicción. En efecto, el método PLS considera en la estimación la variación del espacio de entrada y la correlación entre las variables de entrada y salida⁹².

$$\max_{\alpha_j} [\text{corr}^2(y, X \alpha_j) \text{var}(X \alpha_j)] \quad \text{Ecuación (11)}$$

El modelo de regresión de mínimos cuadrados parciales (PLSR según sus iniciales en inglés) tiene una estructura igual al modelo PCR, pero a menudo tiene mayor capacidad de predicción⁹³.

La regresión continua (CR) es una generalización de los métodos existentes de análisis multivariable, así que PCR, PLSR y MLR son justamente casos especiales del método de regresión continua (CR). Esta generalización está basada en el criterio de estimación de los parámetros α que incluye el así llamado parámetro continuo que da más control sobre la compensación de la varianza⁹⁴.

Máquinas de Vectores Soporte

Una máquina de vector soporte (SVM, según sus iniciales en inglés) es un método de aprendizaje supervisado basado en la teoría del aprendizaje estadístico y la minimización del riesgo estructural. Este método ganó popularidad recientemente

⁹² D. SLISKOVIC, R. GRBIC, and Z. HOCENSKI, Methods for Plant Data-Based Process Modeling in Soft-Sensor Development, Automatica 52, Vol 4, págs 306-318, 2011

⁹³ Ibid

⁹⁴ Ibid

porque no sufre de problemas de mínimos locales y sobreajuste que frecuentemente ocurre en el aprendizaje con redes neuronales. Tanto las redes neuronales artificiales como las máquinas de vectores soportes son aproximaciones universales de cualquier función multivariable a cualquier grado deseado de precisión⁹⁵.

En el modelo de regresión de vector soporte (SVR) el espacio de entrada es primero proyectado a un espacio oculto o latente (espacio futuro) a través de una transformación no lineal y luego una regresión lineal es realizada en el espacio oculto⁹⁶.

$$\hat{y} = f(x, \beta) = \sum_{j=1}^J \beta_j \varphi_j(x) + b \quad \text{Ecuación (12)}$$

donde b es el término de desviación. La compensación entre error de aproximación y la generalización del desempeño es alcanzado por la minimización del siguiente criterio⁹⁷:

$$\min_{\beta} \left(\frac{1}{2} \|\beta\|^2 + C \sum_{i=1}^n |y_i - f(x_i, \beta)|_{\varepsilon} \right) \quad \text{Ecuación (13)}$$

donde C es el criterio de penalización.⁹⁸

Métodos Híbridos

Los métodos híbridos son otro grupo de métodos populares que combinan algunos de los métodos ya mencionados. La hibridación explota las mejores propiedades de los métodos que son combinadas, resultando a menudo procesos más

⁹⁵ D. SLISKOVIC, R. GRBIC, and Z. HOCENSKI, Methods for Plant Data-Based Process Modeling in Soft-Sensor Development, Automatica 52, Vol 4, págs 306-318, 2011

⁹⁶ Ibid

⁹⁷ D. DONG, T. MCAVOY, and L. CHANG, Emission monitoring using multivariate soft sensors, Proceedings of the American Control Conference, Vol 1, págs.761-765, 1995.

⁹⁸ D. SLISKOVIC, R. GRBIC op cit.

precisos, dentro de los cuales se encuentran: No lineal PCA, No lineal PLS y el método de modelo múltiple⁹⁹.

Considerando que en este trabajo de aplicación empleará el método de modelización de redes neuronales artificiales (ANN, según sus iniciales en inglés) para el desarrollo de *soft sensor* para la predicción del PFE del Jet A y T95 del ACPM de la unidad U150, a continuación se hablará en detalle de este tipo de modelos.

Redes Neuronales Artificiales

Las redes neuronales artificiales (ANN) son una técnica muy popular en el modelado basado en datos para construir modelos no lineales. Las ANNs tienen propiedades atractivas como la capacidad de aproximación y generalización universal. Sin embargo estas requieren a menudo una alta relación entre el número de muestras y el número de parámetros del modelo (pesos) con el fin de lograr una estimación de parámetros satisfactoria, lo cual resulta en una alta demanda computacional. Muchos diferentes tipos de ANNs y algoritmos para la estimación de parámetros fueron desarrollados¹⁰⁰.

Una de las más populares ANN es la multicapa perceptron (*MLP*, de acuerdo con sus iniciales en inglés). Las MLP con una capa no lineal oculta y una capa de salida lineal tiene la siguiente estructura¹⁰¹:

$$\hat{y} = \sum_{j=1}^J \beta_j \varphi_j(x) = \sum_{j=1}^J \beta_j \psi_j \left(\sum_{i=1}^m \alpha_{ij} x_i \right) + \beta_0 \quad \text{Ecuación (14)}$$

⁹⁹ D. SLISKOVIĆ, R. GRBIĆ, and Z. HOCENSKI, Methods for Plant Data-Based Process Modeling in Soft-Sensor Development, *Automatica* 52, Vol 4, págs 306-318, 2011.

¹⁰⁰ *Ibid*

¹⁰¹ D. DONG, T. MCAVOY, and L. CHANG, Emission monitoring using multivariate soft sensors, Proceedings of the American Control Conference, Vol 1, págs.761-765, 1995.


donde β_0 es el término de desviación and $\psi_j(.)$ son funciones de activación que tienen una forma sigmoidal. De hecho, la aproximación tiene una proyección del espacio de entrada no lineal con regresión lineal en la segunda parte del modelo. Todos los parámetros del modelo se calculan de acuerdo al siguiente criterio¹⁰²:

$$\min_{\alpha, \beta} (\|y - \hat{y}\|^2) \quad \text{Ecuación (15)}$$

El algoritmo más popular para la estimación simultánea de parámetros es *el error backpropagation algorithm*¹⁰³.

Como se mencionó anteriormente las redes neuronales tipo multicapa perceptron a menudo usan la función de transferencia log-sigmoidea (logsig) (ver figura 10).

Figura 10. Función de Transferencia Log-Sigmoidal.



Fuente: H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB® User Guide, The Math Works, Cap 2,3 y 7, 2012.


Alternativamente, las redes multicapa también usan la función de transferencia tan-sigmoidea (tansig) (ver figura 11)¹⁰⁴.

¹⁰² D. SLISKOVIC, R. GRBIC, and Z. HOCENSKI, Methods for Plant Data-Based Process Modeling in Soft-Sensor Development, Automatica 52, Vol 4, págs 306-318, 2011.

¹⁰³ Ibid

¹⁰⁴ Ibid


Figura 11. Función de Transferencia Tag-Sigmoidea.



Fuente: H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB® User Guide, The Math Works, Cap 2,3 y 7, 2012.

Las neuronas de salida tipo sigmoide en la redes tipo multicapa son a menudo usadas para problemas de reconocimiento de patrones, mientras las neuronas de salida tipo lineal son usadas para problemas de ajuste. La función de transferencia lineal (purelin) se muestra a continuación¹⁰⁵:

Figura 12. Función de Transferencia Lineal.



Fuente: H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB® User Guide, The Math Works, Cap 2,3 y 7, 2012.

Las tres funciones de transferencia descritas aquí son las más comúnmente usadas para la redes multicapa¹⁰⁶.

¹⁰⁵ Ibid

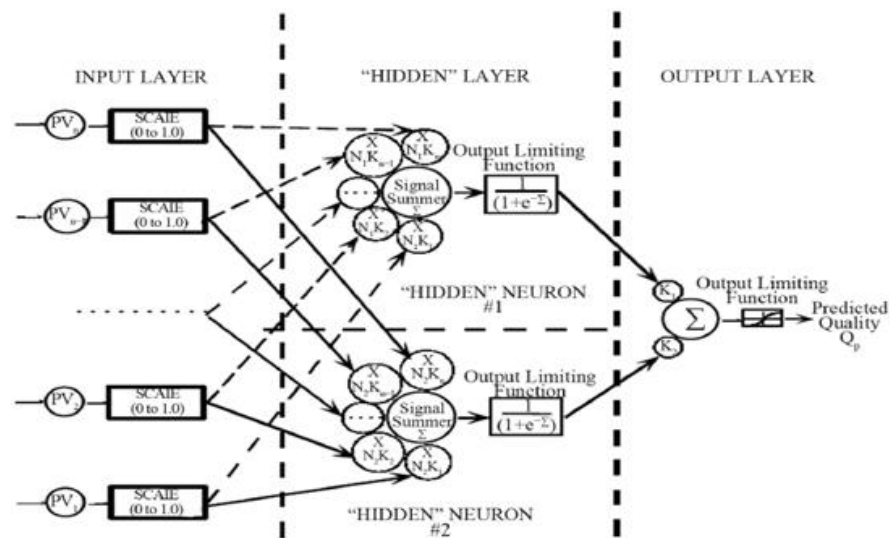
¹⁰⁶ Ibid

Las redes tipo multicapa son aquellas que disponen de conjuntos de neuronas agrupadas en varios niveles o capas. Normalmente, todas las neuronas de una capa reciben señales de entrada de otra capa anterior, más cercana a las entradas de la red, y envían las señales de salida a una capa posterior más cercana a la salida de la red. A estas conexiones se les denomina conexiones hacia adelante o *feedforward*¹⁰⁷.

En las redes multicapa *feedforward* (Figura 13), todas las señales neuronales se propagan hacia adelante a través de las capas de la red. No existen conexiones hacia atrás y normalmente tampoco autorrecurrentes, ni laterales¹⁰⁸.

A continuación se muestra la estructura de una red neuronal tipo multicapa *feedforward*:

Figura 13. Red neuronal tipo multicapa *feedforward*.



Fuente: L. TAOFEEK, G. BABAGANA and A. AKPOVETA, A Review of an Expert System Design for Crude Oil Distillation Column Using The Neural Networks Model

¹⁰⁷ J. HILERA y V. MARTINEZ, Redes Neuronales Artificiales Fundamentos, Modelos y Aplicaciones, Addison-Wesley Iberoamerica, Cap 3, 1995
¹⁰⁸ Ibid

and Process Optimization and Control Using Genetic Algorithm Framework, Advances in Chemical Engineering and Science, págs 164-167, 2013.

Cuando los pesos y desviaciones de la red son inicializados, la red está ya lista para ser entrenada. Las redes tipo multicapa *feedforward* pueden ser entrenadas para funciones de aproximación o reconocimiento de patrones¹⁰⁹.

El proceso de entrenamiento de la red neuronal involucra la sintonización de los valores de los pesos y desviaciones de la red para la optimización del desempeño de la red¹¹⁰.

Hay dos vías diferentes en las que el entrenamiento puede ser implementado, el modo incremental y el modo *batch*. En el modo incremental, el gradiente es calculado y los pesos son actualizados después de que cada entrada es aplicada para la red neuronal. En el modo *batch*, todas las entradas en el conjunto de entrenamiento son aplicadas a la red neuronal antes de la actualización de los pesos.

Para el entrenamiento de redes neuronales multicapa *feedforward* cualquier algoritmo de optimización numérica estándar puede ser usado para optimizar la función de desempeño, pero hay algunos que muestran un desempeño excelente para el entrenamiento de redes neuronales, estos métodos de optimización utilizan ya sea el gradiente del desempeño de la red con respecto a los pesos de la red o el jacobiano de los errores de la red con respecto a los pesos¹¹¹.

¹⁰⁹ H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB © User Guide, The Math Works, Cap 2,3 y 7, 2012.

¹¹⁰ Ibid

¹¹¹ Ibid

El gradiente y el jacobiano son calculados usando la técnica llama *backpropagation algorithm*, los cuales involucran la realización de cálculos hacia atrás y a través de la red¹¹².

Como ilustración de la etapa de entrenamiento, considere el simple algoritmo de optimización de gradiente descendente. Este actualiza los pesos y las desviaciones de la red en la dirección en la cual la función de desempeño disminuye más rápidamente. Una iteración de este algoritmo puede ser escrito así¹¹³:

$$x_{k+1} = x_k - \alpha_k g_k \quad \text{Ecuación (16)}$$

donde x_k es un vector de pesos y desviaciones actuales, g_k es el gradiente actual, y α_k es la relación de aprendizaje. Esta ecuación es iterada hasta que la red converge¹¹⁴.

Una lista de algoritmos de entrenamiento que usan el método basado en el gradiente o Jacobiano se muestra a continuación:

Tabla 4. Funciones de Entrenamiento para redes neuronales multicapa

Function	Algorithm
trainlm	Levenberg-Marquardt
trainbr	Bayesian Regularization
trainbfg	BFGS Quasi-Newton
trainrp	Resilient Backpropagation
trainscg	Scaled Conjugate Gradient
traingb	Conjugate Gradient with Powell/Beale Restarts
traingcf	Fletcher-Powell Conjugate Gradient
traingcp	Polak-Ribière Conjugate Gradient
trainoss	One Step Secant
traingdx	Variable Learning Rate Gradient Descent
traingdm	Gradient Descent with Momentum
traingd	Gradient Descent

Fuente: H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB® User Guide, The Math Works, Cap 2,3 y 7, 2012.

¹¹² H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB® User Guide, The Math Works, Cap 2,3 y 7, 2012.

¹¹³ Ibid

¹¹⁴ Ibid

La más rápida de las funciones de entrenamiento es generalmente la *trainlm*. El método de quasi-Newton *trainbfg*, es también rápido. Ambos métodos tienden a ser poco eficientes para redes grandes (con miles de pesos), haciendo que requieran más memoria y más cálculos para esos casos. También la función *trainlm* tiene mejor desempeño para problemas de funciones de aproximación o ajuste (regresión no lineal) que para problemas de reconocimiento de patrones¹¹⁵.

Las redes multicapa son llamada algunas veces como redes *backpropagation*. Sin embargo, la técnica *backpropagation* que es usada para calcular los gradientes y Jacobianos en una red multicapa también puede ser aplicada para diferentes tipos de arquitectura de redes. De hecho los gradientes y Jacobianos para cualquier red que tenga funciones de transferencia diferenciables, funciones de pesos y de entrada pueden ser calculadas con el proceso *backpropagation*¹¹⁶.

Otra ANN popular es la función base radial (RBFN, de sus iniciales en inglés). Las redes neuronales tipo ANN y RBFN son aproximadores universales. Sin embargo, mientras MLP construye aproximaciones globales de relaciones de entrada y salida; RBFN construye aproximaciones locales. RBFN está compuesta de una capa oculta no lineal y una capa de salida lineal donde la regresión es realizada sobre las variables latentes u ocultas, una transformación de entrada no lineal. En la capa oculta la función base radial es usada como función de activación. La función de activación más popular es la función Gaussiana. En este caso el modelo RBFN tiene la siguiente estructura¹¹⁷:

$$\hat{y} = \sum_{j=1}^J \beta_j \exp\left(-\frac{1}{2\alpha_j^2} \sum_{i=1}^m (x_i - t_{ij})^2\right) + \beta_0 \quad \text{Ecuación (17)}$$

¹¹⁵ H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB © User Guide, The Math Works, Cap 2,3 y 7, 2012.

¹¹⁶ Ibid

¹¹⁷ D. SLISKOVIC, R. GRBIC, and Z. HOCENSKI, Methods for Plant Data-Based Process Modeling in Soft-Sensor Development, Automatica 52, Vol 4, págs 306-318, 2011.

Donde t_j y σ_j son centros y espesores de la función básica. El enfoque más popular para la estimación de parámetros es el aprendizaje combinado. En el primer paso los parámetros t_j y σ_j son determinados, seguido por la estimación de los pesos de las salidas minimizando el error de aproximación del modelo¹¹⁸:

$$\min_{\beta} (\|y - \hat{y}\|^2) \quad \text{Ecuación (18)}$$


Las redes neuronales tipo base radial pueden requerir más neuronas que las redes estándar multicapa *feedforward backpropagation*, pero a menudo pueden ser entrenadas en una fracción de tiempo de lo que toma entrenar una red estándar *feedforward*. Este tipo de redes trabajan mejor cuando muchos vectores de entrenamiento están disponibles¹¹⁹.

La función de transferencia para una neurona base radial es¹²⁰:

$$radbas(n) = e^{-n^2} \quad \text{Ecuación (19)}$$

En la figura 14 se muestra la representación gráfica de la función base radial:

Figura 14. Funciones de transferencia base radial.



Fuente: H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB® User Guide, The Math Works, Cap 2,3 y 7, 2012.

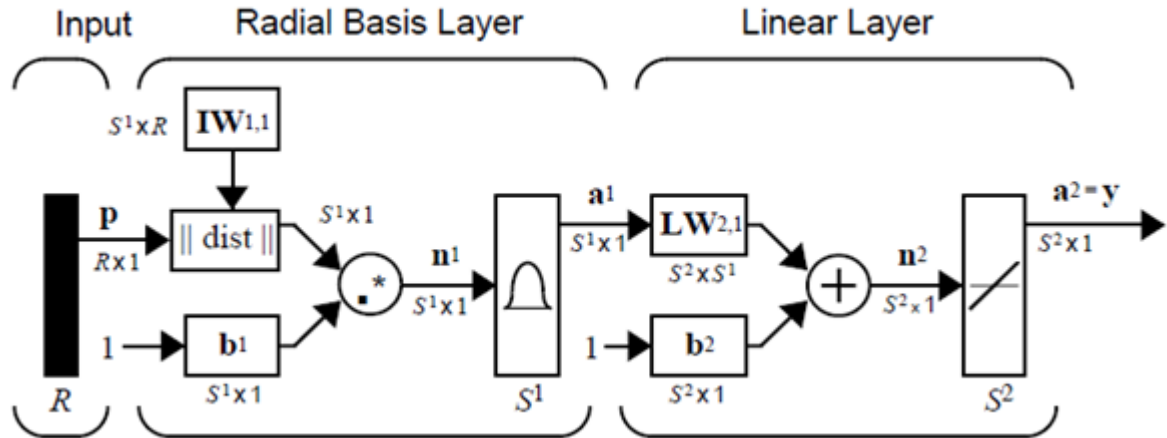
¹¹⁸ D. SLISKOVIĆ, R. GRBIĆ, and Z. HOCENSKI, Methods for Plant Data-Based Process Modeling in Soft-Sensor Development, Automatica 52, Vol 4, págs 306-318, 2011.

¹¹⁹ H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB® User Guide, The Math Works, Cap 2,3 y 7, 2012.

¹²⁰ Ibid

La arquitectura de una red neuronal tipo base radial se muestra a continuación:

Figura 15. Red neuronal tipo base radial.



Fuente: H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB® User Guide, The Math Works, Cap 2,3 y 7, 2012.


Finalmente las redes neuronales tipo *perceptron* son redes de una sola capa cuyos parámetros (pesos y desviaciones) pueden ser entrenados para producir un vector objetivo correcto;. Los *perceptrones* son especialmente adecuados para problemas simples de reconocimiento de patrones. La técnica de entrenamiento para la red neuronal tipo *perceptron* se llama regla de aprendizaje *perceptron* (*learnp*)¹²¹

Las redes tipo *perceptron* utilizan como función de transferencia la *hard-limit*. (Figura 16)¹²²

¹²¹ H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB® User Guide, The Math Works, Cap 2,3 y 7, 2012.

¹²² Ibid

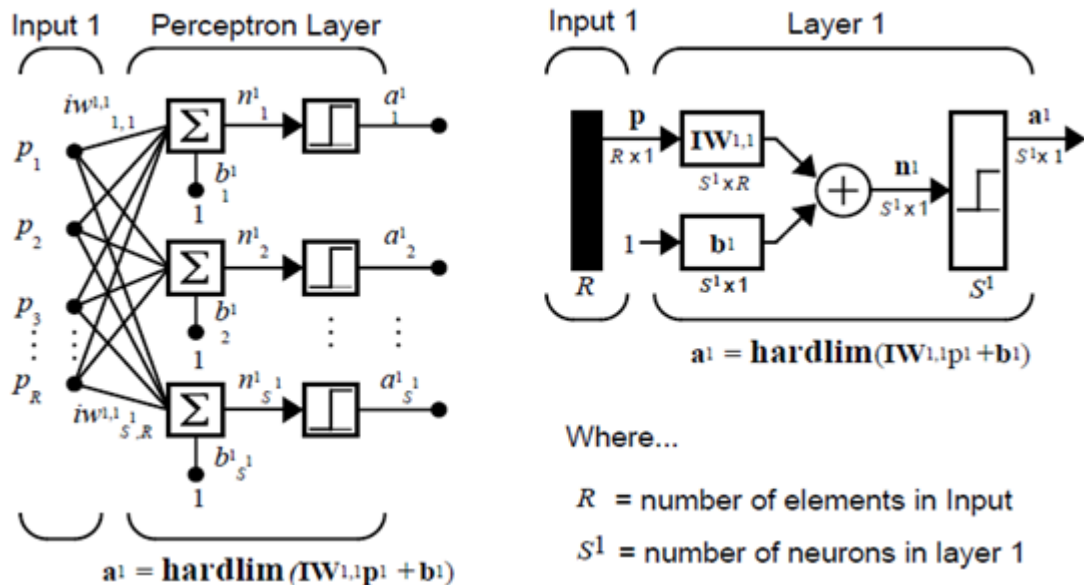
Figura 16. Funciones de transferencia *hard limit*.



Fuente: H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB® User Guide, The Math Works, Cap 2,3 y 7, 2012.

La red *perceptron* consiste en una simple capa de S neuronas *perceptron* conectadas a R entrada a través de un set de pesos w_{ij} como se muestra a continuación¹²³.

Figura 17 Red neuronal tipo perceptron.



Fuente: H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB® User Guide, The Math Works, Cap 2,3 y 7, 2012.

¹²³ H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB® User Guide, The Math Works, Cap 2,3 y 7, 2012.

Validación del Modelo

La función típica de desempeño de las redes neuronales es el promedio de la suma de los errores al cuadrado (MSE, de sus iniciales en inglés), el cual se busca minimizar para obtener el mejor desempeño posible de la red¹²⁴.]

$$F = mse = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - a_i)^2 \quad \text{Ecuación (20)}$$

El error se calcula como la diferencia entre los valores correspondientes obtenidos por el modelo del *soft sensor* y los valores experimentales o los valores obtenidos a través de la base de datos de la planta¹²⁵:

$$e_i = \hat{y} - y_{exp,i} \quad i = 1,2,3, \dots, n \quad \text{Ecuación (21)}$$

La otra función de desempeño comúnmente usada para validar los modelos del *soft sensor* es el coeficiente de correlación Pearson (R) definido por la siguiente ecuación¹²⁶:

$$R = \frac{n \left(\sum_{i=1}^n y_{exp,i} * \hat{y}_i \right) - \left(\sum_{i=1}^n y_{exp,i} \right) * \left(\sum_{i=1}^n \hat{y}_i \right)}{\sqrt{\left[n \sum_{i=1}^n y_{exp,i}^2 - \left(\sum_{i=1}^n y_{exp,i} \right)^2 \right] * \left[n \sum_{i=1}^n \hat{y}_i^2 - \left(\sum_{i=1}^n \hat{y}_i \right)^2 \right]}} \quad \text{Ecuación (22)}$$

Con esta función se busca en crear un gráfico de regresión, el cual muestra la relación entre los valores de salida del modelo del *soft sensor* (*outputs*) y los valores reales de las variables a predecir obtenidos de las bases de datos (*targets*). Si el modelo es perfecto los valores de los *outputs* y *targets* serian exactamente iguales mostrando un valor del coeficiente de correlación R igual a

¹²⁴ Ibid

¹²⁵ ECOPETROL, W:\Planeación de la producción \Planeación y Programación de la Producción\Análisis Económicos\Potenciales, 2014.

¹²⁶ Ibid

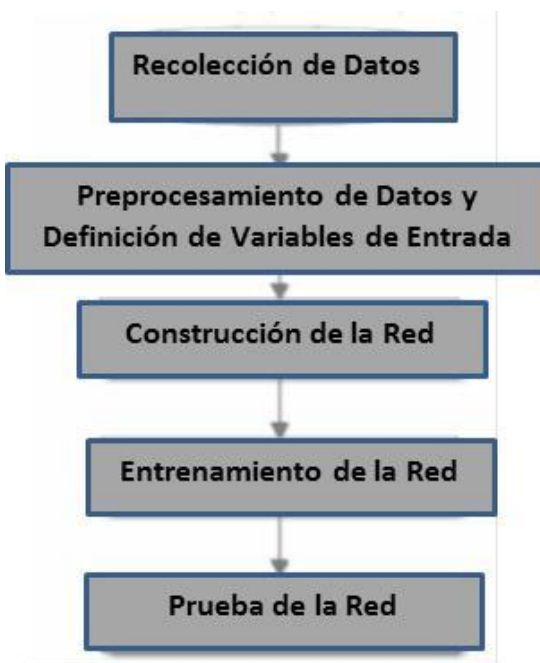
1¹²⁷. Lo modelos que presentan los valores del coeficientes de correlación R más cercanos al valor de 1.0 son los que tiene mejor desempeño de predicción.

¹²⁷ Ibid

5. METODOLOGIA

En la **figura 18** se muestran las etapas que se seguirán para cumplir con el alcance de este trabajo. Básicamente se desarrollarán las siguientes actividades: recolección y pre procesamiento de datos históricos de planta, definición de variables de entrada e intervalos, construcción, entrenamiento y validación de la red neuronal.

Figura 18. Diagrama de Flujo para diseño de una red neuronal

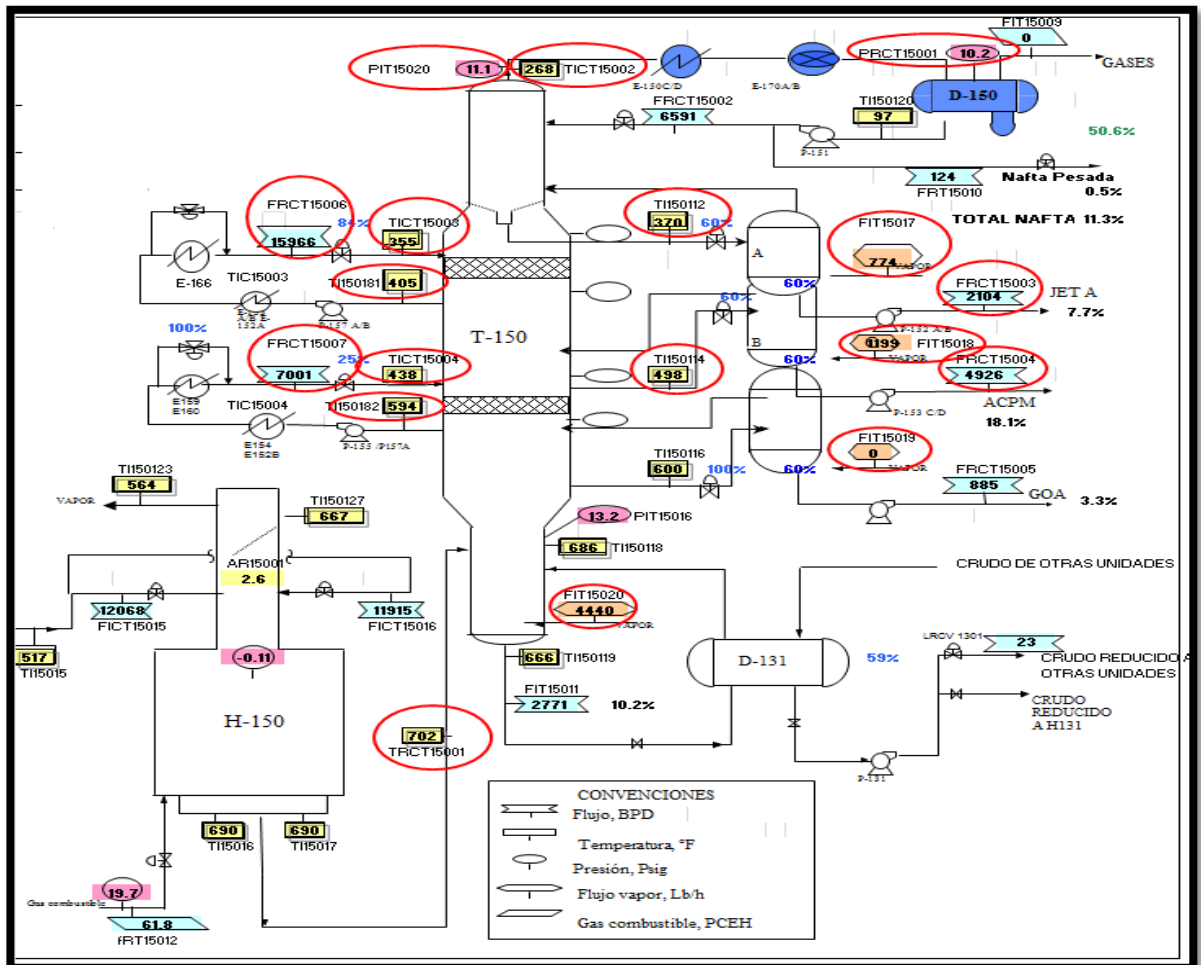


Fuente: M. Al Shamisi, A. Assi and H. Hejase, Using MATLAB® to Develop Artificial Neural Network Models for Predicting Global Solar Radiation in Al Ain City-UAE, InTech, 2011.

5.1. RECOLECCIÓN Y PRE PROCESAMIENTO DE DATOS HISTÓRICOS DE PLANTA Y LABORATORIO.

5.1.1. Condiciones de operación. En la etapa de recolección de datos se bajó la información histórica de las condiciones de operación de la U150 (Presiones, Flujos y Temperaturas) y datos de laboratorio del crudo carga, Jet y ACPM (Gravedad API y Destilación) de la bases de datos PI Data Link y CDLAB respectivamente.

Figura 19. Diagrama de Flujo T150



Fuente: COORDINACIÓN INGENIERÍA DE PROCESO GTE, Gerencia Refinería de Barrancabermeja, Diagrama de Banderas U150, Ecopetrol S.A, 2002.

En la **figura 19** se muestra el diagrama de flujo de la T150 con las variables de operación recopiladas (encerradas en círculo rojo). Los datos históricos de operación de la Unidad U150 tomados de la herramienta PI Data Link fueron tabulados empleando el software Excel (**Ver Figura 20**). Los históricos de las condiciones de operación guardan una estrecha relación con los instrumentos de medición de las variables temperatura (TI), presión (PI) y flujo (FI) los cuales tienen asignado un Tag-PI (etiqueta) para ser buscado en la base datos.

Figura 20. Herramienta PI-Data Link-Excel empleado para Recopilar las Condiciones de Operación de la U150 durante los años 2013 al 2015

Fecha	SALIDA CRUDO T150	SALIDA REF INF U150	REF INF T150	REF INF T150	SALIDA REF MED U150	REF MED T150	CIMA T150	PRESION CIMA T150	REF CIMA T150	SALIDA ACPM U150	SALIDA JP/K U150	KERO/IP U150	ACPM U150	VAP FDO T150	VAP DESP JP/K T151A	VAP DESP ACPM T151B
30/06/2013 11:00	612.35	540.94	383.36	6548.82	428.64	287.11	274.57	11.08	9083.78	510.49	372.46	5097.34	7266.48	1879.49	843.81	2.09
01/07/2013 04:27	600.29	533.92	385.22	6463.87	437.08	276.29	279.09	10.26	8958.82	508.78	374.63	5138.34	7239.47	1784.01	849.60	1.91
03/07/2013 05:10	622.19	559.44	389.94	6468.20	416.40	294.00	279.92	9.41	7302.66	501.13	369.96	3881.93	5687.35	1708.04	851.22	1.83
05/07/2013 05:19	600.27	563.75	400.83	6452.99	429.08	276.93	275.06	10.29	8765.83	501.76	370.13	5498.74	6576.02	1835.79	786.25	1.67
11/07/2013 03:27	610.12	553.49	391.70	6207.58	438.08	281.06	281.01	11.74	8616.96	508.02	381.16	5298.08	7254.53	2390.78	834.64	1.89
20/07/2013 05:28	617.25	581.62	397.23	5531.79	441.96	293.66	267.19	9.58	9108.49	516.19	372.21	5661.19	6607.40	4632.36	833.04	1.92
21/07/2013 05:00	618.27	576.43	399.50	5562.13	450.22	303.94	267.00	8.38	8346.10	517.60	374.88	5768.73	6152.11	4645.71	835.68	1.30
23/07/2013 04:58	605.68	566.88	389.94	5577.16	446.41	300.67	267.15	8.84	7965.92	509.81	371.71	5797.53	5436.21	4556.83	848.00	1.62
25/07/2013 05:26	603.83	566.99	403.29	5581.76	441.92	298.03	266.06	8.93	8300.77	510.06	370.35	5795.70	5710.43	4605.83	832.20	1.51
26/07/2013 09:54	605.36	566.07	402.83	5557.79	446.41	295.97	269.75	8.92	8156.27	510.81	374.95	5776.36	5575.27	4628.65	833.25	1.79
27/07/2013 05:32	601.10	564.48	401.72	5575.71	443.78	293.09	270.21	8.91	8186.46	509.05	373.57	5894.96	5598.10	4617.88	834.01	1.75

De acuerdo con el objetivo de este trabajo se obtuvieron valores históricos promedio hora de las condiciones de operación de la torre de destilación atmosférica T150 y las torres despojadoras T151A/B desde julio del año 2013 hasta Octubre del año 2015. En la **Tabla 5** se muestran las condiciones de operación de la T150 que se obtuvieron de PI-Data Link con su respectivo Tag-PI y unidades de medición:

Tabla 5. Variables de Operación T150.

Variables de Operación	Tag-PI	Unidades
Temperatura Salida H150 (TSH)	u150-TRCT15001	°F
Temperatura Salida Reflujo Inferior (TSRI)	u150-TI150182	°F
Temperatura Entrada Reflujo Inferior (TERI)	U150-TICT15004	°F
Temperatura Salida Reflujo Medio (TSRM)	u150-TI150181	°F
Temperatura Entrada Reflujo Medio (TERM)	U150-TICT15003	°F
Temperatura Cima T150 (TC)	U150-TICT15002	°F
Temperatura Salida ACPM (TSA)	u150-TI150114	°F
Temperatura Salida JET (TSJ)	u150-TI150112	°F
Reflujo de Cima T150 (RC)	u150-FRCT15002	BPD
Producción de JET (PJ)	u150-FRCT15003	BPD
Producción de ACPM (PA)	u150-FRCT15004	BPD
Reflujo Medio T150 (RM)	U150-FRCT15006	BPD
Reflujo Inferior T150 (RI)	u150-FRCT15007	BPD
Vapor al Fondo T150 (VF)	u150-fIT15020	BPD
Vapor al Fondo Despojadora Jet T151A (VFA)	u150-fIT15017	lb/h
Vapor al Fondo Despojadora ACPM T151B (VFB)	u150-fIT15018	lb/h
Vapor al Fondo Despojadora GOA T151C (VFC)	u150-fIT15019	lb/h
Presión Tambor D150 (PD)	u150-PRCT15001	psig
Presión Cima T150 (PC)	u150-PIT15020	psig

Datos de laboratorio

Respecto a los parámetros de calidad del crudo de carga y los productos (Jet y ACPM); los históricos diarios de laboratorio se obtuvieron de la base de datos CDLAB y se tabularon en el software Excel (**Ver Figura 21 y 22**) desde Julio de

2013 a Octubre de 2015. De acuerdo con los objetivos de este trabajo, los parámetros de calidad que se consideraron para las corrientes mencionadas fueron los siguientes:

- Crudo carga: Gravedad API (ASTM D5002) Muestra Mezcla Parafínica U150 (Desc MP3865A/B)
- Jet : Destilación ASTM D86 (Punto Final de Ebullición °F) Muestra T151A Jet-A U150.
- ACPM: Destilación ASTM D86 (T95%Vol Recobrado °F) Muestra T151B ACPM U150.

Figura 21. Herramienta CD-LAB para recopilar datos de laboratorio

The screenshot shows the CD-LAB web application interface. The browser address bar displays `http://bjaessitbl/integracion/MainCDLAB.aspx`. The page header includes the logo for **Gerencia Refinería Barrancabermeja** and the text **Sistema de Información de Laboratorio Industrial - Inspección de Calidad**. The user is logged in as **Juan Carlos Arias Molina** with **46** users.

The main content area is titled **Tener en Cuenta** and includes a filter for **Muestras Con Vo Bo** and **Todas las muestras**. Below this, there is a section for selecting date ranges: **Escoja los rangos de fechas a mostrar en el reporte:**. Two calendar views are shown for **January 2013** and **January 2016**.

Below the calendars, there are buttons for **Por Estudio**, **Todos Estudios**, **Por Muestras**, and **Por Filtros**. The **Estudios** section contains a list of studies and their corresponding time ranges:

Estudios	Hora Desde	Hora Hasta
TOPPING 150	06:00:00 AM	02:00:00 PM
TOPPING 200	07:00:00 AM	03:00:00 PM
TOPPING 2000	08:00:00 AM	04:00:00 PM
TOPPING 2100	09:00:00 AM	05:00:00 PM
TOPPING 250	10:00:00 AM	06:00:00 PM

An **Ejecutar consulta** button is located at the bottom right of the table.

Figura 22. Datos CD-LAB exportados a Excel.

Estudio	Fecha	Muestra	Análisis	Método	Valor	Uom	Inspec.	Id Muestra USR	Ingreso Resultado
TOPPING 150	01/01/2012 04:47	T-151B ACPM U-150	95% vol. RECOBRADO	ASTM D 2887 DESTILACION POR CROMATOGRAFI	658.6	°F	IN	T-151B ACPM U-150	12-01-01 04:57:30 E0220278
TOPPING 150	01/01/2012 04:47	T-151B ACPM U-150	95% vol. RECOBRADO	ASTM D 2887 DESTILACION POR CROMATOGRAFI	348.1	°C	N/A	T-151B ACPM U-150	12-01-01 04:57:37 E0220278
TOPPING 150	01/01/2012 13:47	T-151B ACPM U-150	95% vol. RECOBRADO	ASTM D 2887 DESTILACION POR CROMATOGRAFI	658.6	°F	IN	T-151B ACPM U-150	12-01-01 14:07:54 PENLIMS
TOPPING 150	01/01/2012 13:47	T-151B ACPM U-150	95% vol. RECOBRADO	ASTM D 2887 DESTILACION POR CROMATOGRAFI	348.1	°C	N/A	T-151B ACPM U-150	12-01-01 14:08:02 PENLIMS
TOPPING 150	02/01/2012 04:14	T-151B ACPM U-150	95% vol. RECOBRADO	ASTM D 2887 DESTILACION POR CROMATOGRAFI	661.8	°F	IN	T-151B ACPM U-150	12-01-02 05:00:30 PENLIMS
TOPPING 150	02/01/2012 04:14	T-151B ACPM U-150	95% vol. RECOBRADO	ASTM D 2887 DESTILACION POR CROMATOGRAFI	349.9	°C	N/A	T-151B ACPM U-150	12-01-02 05:00:37 PENLIMS
TOPPING 150	03/01/2012 02:10	T-151B ACPM U-150	95% vol. RECOBRADO	ASTM D 2887 DESTILACION POR CROMATOGRAFI	648.4	°F	IN	T-151B ACPM U-150	12-01-03 02:22:09 PENLIMS
TOPPING 150	03/01/2012 02:10	T-151B ACPM U-150	95% vol. RECOBRADO	ASTM D 2887 DESTILACION POR CROMATOGRAFI	342.4	°C	N/A	T-151B ACPM U-150	12-01-03 02:22:17 PENLIMS
TOPPING 150	04/01/2012 00:30	T-151B ACPM U-150	95% vol. RECOBRADO	ASTM D 2887 DESTILACION POR CROMATOGRAFI	663.2	°F	IN	T-151B ACPM U-150	12-01-04 04:14:39 PENLIMS
TOPPING 150	04/01/2012 00:30	T-151B ACPM U-150	95% vol. RECOBRADO	ASTM D 2887 DESTILACION POR CROMATOGRAFI	350.7	°C	N/A	T-151B ACPM U-150	12-01-04 04:14:47 PENLIMS
TOPPING 150	05/01/2012 01:53	T-151B ACPM U-150	95% vol. RECOBRADO	ASTM D 2887 DESTILACION POR CROMATOGRAFI	696.4	°F	OUT	T-151B ACPM U-150	12-01-05 03:19:40 E0223541
TOPPING 150	05/01/2012 01:53	T-151B ACPM U-150	95% vol. RECOBRADO	ASTM D 2887 DESTILACION POR CROMATOGRAFI	369.1	°C	N/A	T-151B ACPM U-150	12-01-05 03:19:47 E0223541

Preprocesamiento de datos.

Teniendo en cuenta que las muestras de Jet-A y ACPM se toman en una hora específica una vez al día (Turno C Muestras de las 11pm) cuya fecha y hora es suministrada por CDLAB, fue necesario filtrar con ayuda de la herramienta PI-Data Link, las condiciones de operación promedio hora y así obtener las que se tenían 30 minutos antes del muestreo. El tiempo de 30 minutos se sustenta porque de acuerdo con la experiencia, los ajustes en las condiciones de operación de la U150 se ven reflejados en la calidad de los productos luego de 30 minutos.

Una vez consolidados los datos diarios de los parámetros de punto final de ebullición (PFE) para el Jet-A; y T95%Vol Recobrado para el ACPM con sus respectivas condiciones de operación, se realizó un nuevo filtro para obtener los días para los cuales se tiene datos de gravedad API del crudo carga asumiendo una baja variabilidad en su composición durante el día.

En la **tabla 6** se muestra el resumen de las variables independientes (Xi) y dependientes (Yi):

Con esto finalmente se obtuvieron dos matrices de datos, una para el punto final de ebullición (PFE) del Jet-A (Variable Dependiente Y1) y otra para la T95%vol (Variable Dependiente Y2) con sus respectivas condiciones de operación y calidad de crudo de carga (Variables Independientes X1,X2), tal y como se muestra en las **tablas 7 y 8**

Tabla 6. Variables Dependientes (Y) e Independientes (X)

Y1	PFE	Punto Final de Ebullición JET
Y2	T95	T95%Vol Recobrado ACPM
X1	SALIDA CRUDO H150	u150-TRCT15001
X2	SALIDA REF INF	u150-ti150182
X3	REF.INF.T150	U150-TICT15004
X4	REF INF T150	u150-fRCT15007
X5	SALIDA REF MED	u150-ti150181
X6	REF.MED.T150	U150-TICT15003
X7	CIMA T150	U150-TICT15002
X8	PRESION .CIMA T150	u150-PIT15020
X9	REF CIMA T150	u150-fRCT15002
X10	SALIDA ACPM	u150-ti150114
X11	SALIDA JP/K	u150-ti150112
X12	KERO/JP	u150-fRCT15003
X13	ACPM	u150-fRCT15004
X14	VAP FDO T150	u150-flT15020
X15	VAP DESP JP/K T 151A	u150-flT15017
X16	VAP DESP ACPM T 151B	u150-flT15018
X17	VAP DESP GOA T 151C	u150-flT15019
X18	PRESION T150	u150-PRCT15001
X19	REF MEDIO T 150	U150-FRCT15006
X20	COMPOSICION CRUDO	GRAVEDAD API

Tabla 7. Matriz Datos PFE Jet-A

Muestra	Y1	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	X13	X14	X15	X16	X17	X18	X19	X20
	PFE	SALIDA CRUDO		REF. INF. T150	SALIDA REF. MED	REF. MED. T150	CIMA T150	PRESION. CIMA		SALIDA ACPM	SALIDA JP/K	KERO/JP	ACPM	VAP FDO T150	VAP DESP JP/K T	VAP DESP ACPM	VAP DESP GOA	PRESION T150	REF. MEDIO	T	CRUDO
		H150	SALIDA REF. INF					U150-T150	T150						REF. CIMA T150	U150-FRCT15001	U150-FRCT15006		151A	T 151B	
U150-FRCT15001	U150-F150182	T150	U150-FRCT15007	U150-F150181	U150-T15003	U150-T15002	U150-FRCT15002	U150-F150114	U150-F150112	U150-FRCT15003	U150-FRCT15004	U150-F150120	U150-F150107	U150-F150108	U150-F150109	U150-PRCT15001	U150-FRCT15006	API			
1	485	612.35	540.94	383.56	6548.82	428.64	287.11	274.57	11.08	9083.78	510.49	372.46	5097.54	7266.48	1879.49	843.81	2.09	Bad Input	8.90	11282.22	41.00
2	557	600.29	533.92	385.22	6463.87	437.08	276.29	279.09	10.26	8958.82	508.78	374.63	5138.34	7239.47	1784.01	849.60	1.91	Bad Input	8.20	11212.36	47.30
3	472	622.19	559.44	389.94	6468.20	416.40	294.00	279.92	9.41	7302.66	501.13	369.96	3881.93	5687.35	1708.04	851.22	1.83	Bad Input	8.27	11341.64	41.40
4	473	600.27	563.75	400.83	6452.99	429.08	276.93	275.06	10.29	8765.83	501.76	370.13	5498.74	6576.02	1835.79	786.25	1.67	Bad Input	8.86	11350.60	45.40
.
.
.
662	409	621.51	554.22	398.20	5826.41	383.39	306.41	266.22	11.20	6384.68	469.76	354.39	1879.43	5808.20	4885.82	16.98	1756.45	26.90	10.13	13950.77	33.70

Tabla 8. Matriz Datos T95 ACPM

Muestra	Y2	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	X13	X14	X15	X16	X17	X18	X19	X20
	T95	SALIDA CRUDO		REF. INF. T150	SALIDA REF. MED	REF. MED. T150	CIMA T150	PRESION. CIMA		SALIDA ACPM	SALIDA JP/K	KERO/JP	ACPM	VAP FDO T150	VAP DESP JP/K T	VAP DESP ACPM	VAP DESP GOA	PRESION T150	REF. MEDIO	T	CRUDO
		H150	SALIDA REF. INF					U150-T150	T150						REF. CIMA T150	U150-FRCT15001	U150-FRCT15006		151A	T 151B	
U150-FRCT15001	U150-F150182	T150	U150-FRCT15007	U150-F150181	U150-T15003	U150-T15002	U150-FRCT15002	U150-F150114	U150-F150112	U150-FRCT15003	U150-FRCT15004	U150-F150120	U150-F150107	U150-F150108	U150-F150109	U150-PRCT15001	U150-FRCT15006	API			
1	634	612.35	540.94	383.56	6548.82	428.64	287.11	274.57	11.08	9083.78	510.49	372.46	5097.54	7266.48	1879.49	843.81	2.09	Bad Input	8.90	11282.22	41.00
2	651	600.29	533.92	385.22	6463.87	437.08	276.29	279.09	10.26	8958.82	508.78	374.63	5138.34	7239.47	1784.01	849.60	1.91	Bad Input	8.20	11212.36	47.30
3	629	622.19	559.44	389.94	6468.20	416.40	294.00	279.92	9.41	7302.66	501.13	369.96	3881.93	5687.35	1708.04	851.22	1.83	Bad Input	8.27	11341.64	41.40
4	632	600.27	563.75	400.83	6452.99	429.08	276.93	275.06	10.29	8765.83	501.76	370.13	5498.74	6576.02	1835.79	786.25	1.67	Bad Input	8.86	11350.60	45.40
.
.
.
625	608	621.51	554.22	398.20	5826.41	383.39	306.41	266.22	11.20	6384.68	469.76	354.39	1879.43	5808.20	4885.82	16.98	1756.45	26.90	10.13	13950.77	33.70

Como se puede observar en las **tablas 7 y 8** el número de datos recopilados para el PFE del Jet-A fueron 662 y para la T95 del ACPM fueron 625.

Con el fin de depurar los datos que serán empleados para la definición de variables de entrada al modelo se precedió como sigue:

- Determinar los valores promedio, desviación estándar y valores mínimos y máximos de todas las variables. Este análisis se realizó con el fin de identificar

puntos de operación que estén fuera de los rangos debido a problemas de operación.

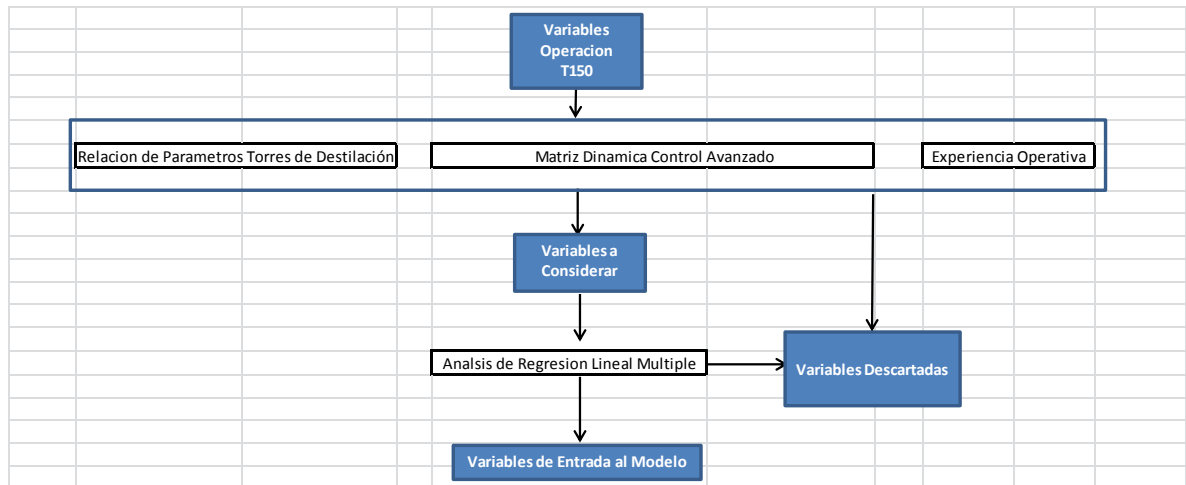
- Finalmente con el objetivo de identificar datos atípicos que puedan afectar la definición de variables de entrada al modelo, se utilizó el método de diagnóstico de residuos estandarizados los cuales se obtienen a partir de un análisis de regresión lineal múltiple entre las variables dependientes (Y1 y Y2) e independientes (X1,X2...X20). El criterio empleado para eliminar datos atípicos fue: aquellas observaciones o muestras que tengan un valor absoluto en el residual estandarizado $\sigma > \pm 2$ se consideran valores atípicos o “*Outliers*”¹²⁸

5.2. DEFINICIÓN DE LAS VARIABLES DE ENTRADA AL MODELO Y SUS INTERVALOS

Para la definición de las variables de entrada al modelo y sus intervalos se utilizaron como criterios la matriz dinámica del control avanzado de proceso de la U150, la relación de parámetros para torres de fraccionamiento, la experiencia operativa y un análisis de regresión lineal múltiple. De las variables de operación recopiladas, con los primeros tres criterios se realizó una pre selección simultánea de las posibles variables de entrada al modelo las cuales finalmente fueron filtradas por medio del análisis estadístico de regresión lineal múltiple como se muestra en el siguiente diagrama de flujo:

¹²⁸ A. PARDO, Análisis de Datos y Multivariable, Dpto de Materiales Universidad Complutense, Cap 18, 2000.

Figura 23. Diagrama de Flujo Definición Variables de Entrada a Modelo.



5.2.1. Matriz dinámica del control avanzado de proceso U150. Para definir las variables de entrada al modelo se tomó como referencia la matriz dinámica del sistema de control avanzado instalado actualmente en la U150, donde se muestra el efecto de las variables independientes (manipuladas): presión T150, temperatura de cima T150, producción de Jet, producción de ACPM, producción de GOA, reflujo medio T150 y reflujo inferior T150; y de las variables de perturbación (*FeedForward*) tales como vapor de despojo T150 y presión D245 sobre las variables dependientes (controladas) dentro de las cuales se encuentran el punto final de ebullición (PFE) de los productos Jet y ACPM.

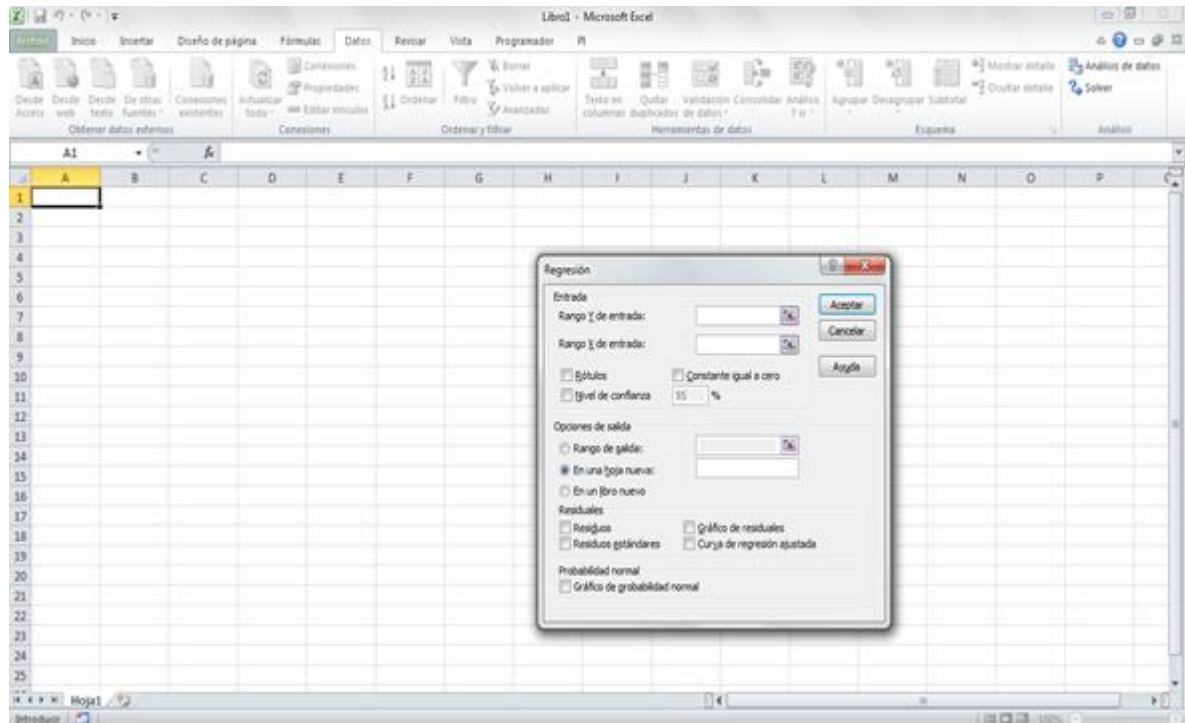
5.2.2. Diagrama de relación de parámetros en destilación. Para la definición de variables de entrada para el desarrollo del modelo del *soft sensor* también se utilizó como criterio el diagrama de relación de parámetros, el cual muestra que hay tres factores primarios que influyen directamente sobre el proceso de destilación y la calidad de los productos; estos son: la temperatura, presión y composición de la carga y a su vez la temperatura está gobernada por otros dos factores secundarios la operación de los reflujo y la operación del rehervidor y/o horno.

5.2.3. Experiencia operativa. El criterio de experiencia operativa fue también utilizado para la determinación de las variables de entrada al modelo de predicción del *soft sensor*, para esto se realizaron entrevistas a los operadores de tablero COR (Cuarto de Control Centralizado) con más de 10 años de experiencia; se les preguntó según su conocimiento cuáles son las variables de operación que se deben manipular para controlar el PFE (Punto Final de Ebullición) del producto Jet-A y la T95 (Temperatura del 95% vol de recobrado) del ACPM.

5.2.4. Análisis de regresión lineal múltiple. Finalmente para la definición de variables de entrada al modelo se utilizó la herramienta estadística análisis de regresión lineal múltiple donde a través del criterio de significancia, solo se incorporan las variables que contribuyen de manera significativa al ajuste del modelo¹²⁹, lo cual se cumple si el coeficiente de correlación parcial es significativamente diferente de cero con una probabilidad de entrada menor a 0.05, dicho en otras palabras se realizó un Análisis de varianza ANOVA con el fin de determinar, con un 95 % de intervalo de confianza las variables que tienen una incidencia sobre la variable de respuesta. El análisis de regresión lineal se llevó a cabo con la herramienta análisis de datos modulo regresión del software Excel. (Ver Figura 24).

¹²⁹ L. FORTUNA, S. GRAZIANI, and M. XIBILIA, Soft sensors for product quality monitoring in debutanizer distillation columns, Control Engineering Practice, Vol 13, págs 499-508, 2005.

Figura 24. Herramienta Análisis de Datos Modulo Regresión Software Excel.



5.2.5. Definición de intervalos de las variables de entrada. Una vez definidas las variables de entrada al modelo del *soft sensor* se definieron sus intervalos tomando como referencia, las ventanas de operación por integridad especificadas para algunas variables de la U150, la tabla de control del manual de operación de la planta mostrada en el marco teórico y los valores mínimos y máximos encontrados en los datos históricos recopilados para aquellas que no tienen ventanas de integridad asociadas. Las ventanas de operación se tomaron del módulo puntos críticos de control (Consultas PCC) de la herramienta RIS (*Refinery Information System*) de la gerencia refinería de Barrancabermeja (GRB) como se muestra en la **figura 25**.

Figura 25. Herramienta RIS Modulo Ventanas Operativas Consultas PCC.

Item	TAG	DESCRIPCION TAG	UNIDAD	VOH	VOL	GCH	GCL	TA	TC	#V	Hab.	NivSeguim	
1	U150-TI15012	TEMPERATURA ENTRADA AL DESALADOR	ADM	270	--	265	--	60	60	5	SI	1	
2	U150-CLOR_AGUA_SALIDA_D150	CLORUROS AGUA SALIDA D-150	ADM	60	--	41	--	60	120	1	NO	1	
3	U150-BSW_SALIDA_DES_D152	BSW	ADM	--	--	0,5	--	60	120	1	NO	1	
4	U150-SAL_SALIDA_DES_D152	CONTENIDO DE SAL CRUDO SALIDA D-152	ADM	--	--	2	--	60	120	1	NO	1	
5	U150-AGUACRUDDO152	RELACION AGUACRUDDO AL D152	ADM	--	--	7	--	4	120	120	5	SI	1
6	U150-TI15015	TEMPERATURA DE PRECALIENTE H150	ADM	600	440	580	445	60	60	5	NO	1	
7	U150-AR15001	EXCESO OXIGENO H150	ADM	9999	1,8	5	2	20	10	5	SI	1	
8	U150-TI150129	TEMPERATURA TUBO 23 SERPENTIN A H-150	ADM	1300	--	1200	--	720	720	3	NO	1	
9	U150-TI150130	TEMPERATURA TUBO 1 SERPENTIN A H-150	ADM	1300	--	1200	--	720	720	3	SI	1	
10	U150-TI150131	TEMPERATURA TUBO 1 SERPENTIN B H-150	ADM	1300	--	1200	--	720	720	3	SI	1	
11	U150-TI150132	TEMPERATURA TUBO 12 SERPENTIN B H-150	ADM	1300	--	1200	--	720	1440	3	NO	1	
12	U150-TI150133	TEMPERATURA TUBO 12 SERPENTIN A H-150	ADM	1300	--	1200	--	720	720	3	NO	1	
13	U150-TI150135	TEMPERATURA TUBO 23 SERPENTIN A H-150	ADM	1300	--	1200	--	720	720	3	SI	1	
14	U150-PIC15010	PRESION DE TRO H-150	IN H2O	-0,01	--	-0,05	-0,15	20	20	5	SI	1	
15	U150-FIC15015	FLUJO SERPENTIN A H-150	ADM	--	6800	--	9500	30	20	3	SI	1	
16	U150-FIC15016	FLUJO SERPENTIN B H-150	BLSD	--	6800	--	9500	30	20	3	SI	1	
17	U150-TRCT15001	TEMPERATURA DE SALIDA H-150	ADM	--	--	680	570	30	20	3	NO	1	
18	U150-TI15016	TEMPERATURA SALIDA SERPENTIN A H-150	°F	685	--	--	--	60	20	3	SI	1	
19	U150-TI15017	TEMPERATURA SALIDA SERPENTIN B H-150	°F	735	--	--	--	60	20	3	SI	1	
20	U150-CARGA	CARGA A LA UNIDAD U150	ADM	40000	29500	39800	30000	60	60	5	SI	1	
21	U150-PI15110	PRESION ZONA FLASH T152	PSIG	--	--	13	--	30	30	5	NO	1	
22	U150-TI15073	TEMPERATURA ZONA FLASH T152	°F	375	--	--	230	30	30	8	SI	1	
23	U150-PI15133	PRESION EN D162	PSIA	20	--	16	--	30	30	5	SI	1	
24	U150-TI15006	TEMPERATURA CIMA T-152	ADM	350	190	320	195	70	480	8	SI	1	
25	U150-TI15088	TEMPERATURA D162	°F	--	--	120	--	30	30	5	SI	1	
26	U150-PI15051	VAPOR DESPOJO FONDO T152	ADM	--	--	--	1200	120	120	5	NO	1	
27	U150-L15020	NIVEL FONDO T-152	%	80	30	75	35	20	15	3	SI	1	
28	U150-L15021	NIVEL DE NAFTA D-162	ADM	50	15	48	18	60	30	3	SI	1	
29	U150-L15022	NIVEL AGUA BOTA D162	%	80	30	70	40	15	5	2	SI	1	
30	U150-CLOR_AGUA_D162	CLORURO AGUA SALIDA D162	ADM	50	--	31	--	60	120	1	NO	1	
31	U150-PT15016	PRESION ZONA FLASH T150	ADM	--	--	20	--	30	30	5	SI	1	
32	U150-TI150118	TEMPERATURA ZONA FLASH T150	ADM	685	--	--	570	30	30	5	NO	1	
33	U150-PRCT15001	PRESION CIMA T-150	PSIG	14	--	13	--	30	30	5	SI	1	

5.3. CONSTRUCCIÓN, ENTRENAMIENTO Y VALIDACIÓN DE LA REDES NEURONALES.

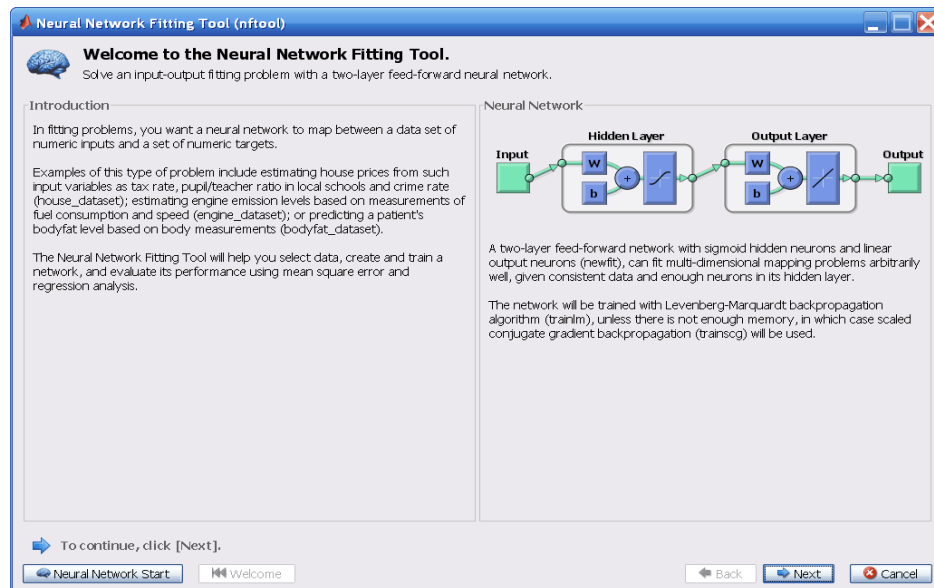
En la construcción, entrenamiento y validación de las redes neuronales para la predicción del PFE del Jet y T95 del ACPM se utilizó el software comercial MATLAB® R2012b donde se evaluaron diferentes tipos de redes, funciones de transferencia, algoritmos de entrenamiento y métodos de validación. El resultado final de esta etapa será el mejor modelo de predicción para el *soft sensor*.

5.3.1. Construcción de las redes neuronales. Para la construcción de las redes neuronales se utilizaron las herramientas NFTOOL (*Neural Network Fitting Tool*) y NNTOOL (*Neural Network Tool*) de Matlab ®. La herramienta NFTOOL (**Ver Figura 26**) es una red neuronal multicapa estándar predefinida (*Multilayer perceptron feed-forward backpropagation MLPFFB*) de dos capas (Capa oculta y de salida) tipo *feed-forward* usada como función de aproximación (Regresión no

lineal) para predicción de datos a partir de información real conocida (*Inputs-Targets*) que es alimentada en el *software*. La capa oculta (*Hidden layer*) tiene una función de transferencia tipo sigmoïdal y la capa de salida (*Output Layer*) una función de transferencia tipo lineal, por default el número de neuronas en la capa oculta es de 10 el cual puede ser modificado si se requiere mejorar el desempeño en la predicción de la red (**Ver figura 27**).

Introduciendo al *software* NFTOOL (**Ver Figura 9**) los datos históricos depurados de las variables de entrada (Condiciones de Operación y Calidad de Carga) previamente definidas (*inputs*) y los datos históricos correspondientes de las variables de salida a predecir PFE del Jet y T95 del ACPM (*targets*) se construyeron dos modelos de redes neuronales para predecir el PFE del Jet y dos modelos para la T95 del ACPM con diferente número de neuronas en la capa oculta cumpliendo con el criterio de que el neuronas no debe ser mayor a 1.5 veces el número de variables de entrada (*inputs*)¹³⁰.

Figura 26. Herramienta NFTOOL (NEURAL NETWORK FITTING TOOL).



¹³⁰ A. ROGINA, L. SISCO, I. MOLHER, Z. UJEVIC and N. BOLF, Soft sensors for continuous product quality estimation (in crude distillation unit), Chemical engineering research and design, Vol 89, págs 2070-2077, 2011.

Figura 27. Arquitectura de la red NFTOOL (NEURAL NETWORK FITTING).

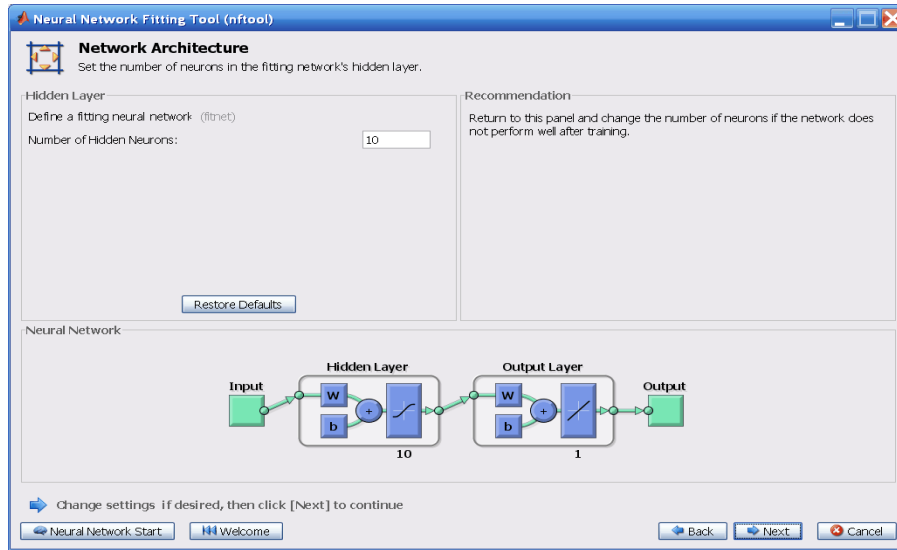
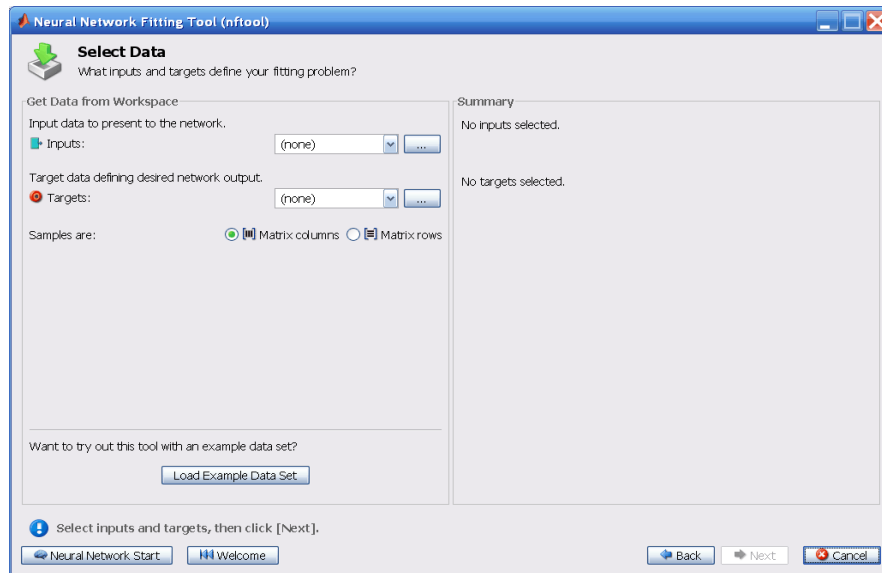


Figura 28. Ambiente para introducción de datos en la herramienta NFTOOL.



La herramienta NNTOOL (Ver Figura 29) permite construir diferentes tipos de redes neuronales entre las cuales se encuentran *multilayer perceptron feed-forward backpropagation (MLPFFB)*, *multilayer perceptron cascade-forward backpropagation (MLPCFB)*, *radial basis (RB)*, *multilayer elman backpropagation (MLEB)*, *multilayer recurrent (MLR)*, *perceptron (P)*, *linear layer (LL)*, *probabilistic*

(PB) y redes dinámicas (*feed-forward time delay*, *feed-forward distributed time delay*, *LVQ*, *NARX*), para las redes tipo multicapa se tiene la opción de definir el número capas ocultas ,el número de neuronas por capa oculta y el tipo de función de transferencia para las capas ocultas y de salida con las siguientes tres opciones: *logsim* (*log-sigmoid*), *tagsim* (*tan-sigmoid*) y *purelin* (*linear*). Para el caso de la red neuronal tipo *perceptron* (Ver Figura 30) se tiene la opción de elegir la función de transferencia *Hardlim* (*Hard Limit*) y *Hardlims* (*Hard Limits*).

La red neuronal tipo *radial basis* en la herramienta NNTOOL presenta dos opciones de red: (Ajuste Exacto) *exact fit* y (Pocas Neuronas) *fewer neurons* (Ver figura 31) que trabajan con la función de transferencia *radbas*. Ambos tipos de red RB tiene un parámetro llamado constante de propagación (*Spread constant*) que por *default* es 1.0, la tipo RB *fewer neurons* además de esta constante tiene otro parámetro llamado objetivo de desempeño (*Performance Goal*) que por *default* es 0.0 y representa MSE (*Media Square Error*) el error cuadrado promedio de la predicción comparado con el valor real (Ver figura 32) lo cual se explicara con más detalle en etapa de validación y prueba de las redes neuronales.

Figura 29. Herramienta NNTOOL (NEURAL NETWORK TOOL).

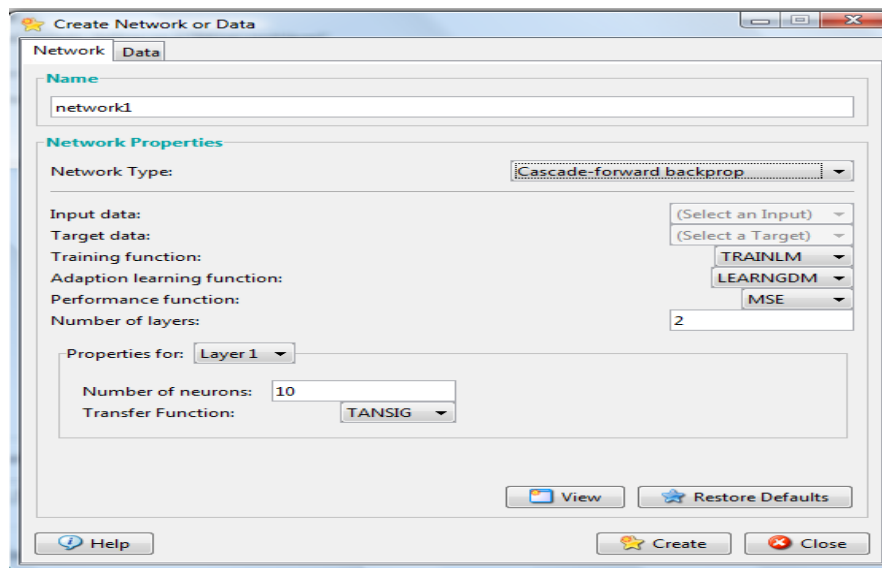


Figura 30. Herramienta NNTOOL red neuronal tipo *perceptron*




Figura 31. Herramienta NNTOOL tipos de redes neuronales *radial basis*.

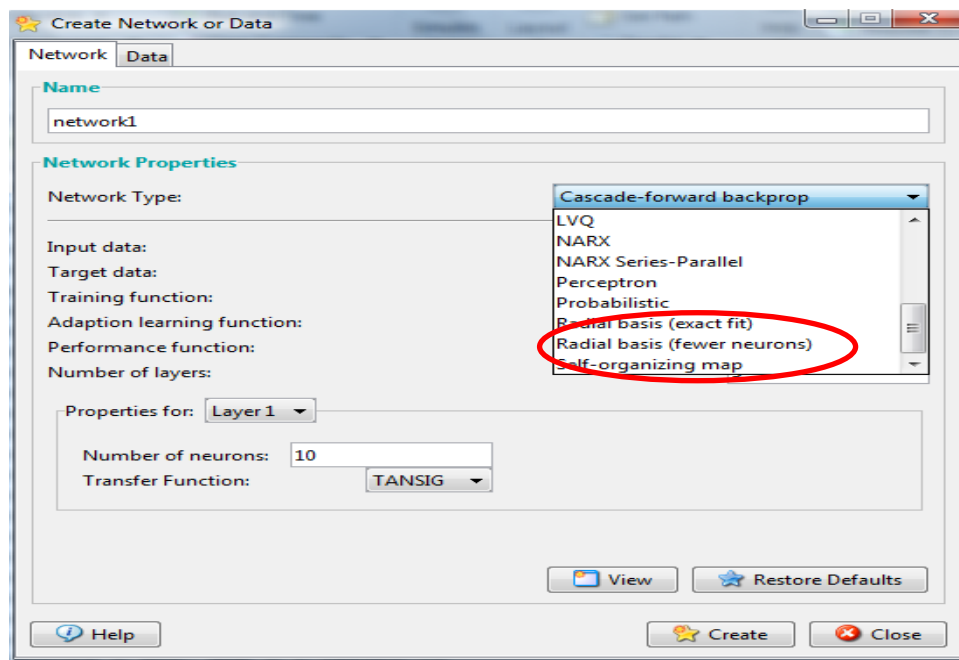



Figura 32. Herramienta NNTOOL parámetros redes neuronales tipo *radial basis*.



Tomando como referencia el trabajo publicado por Rogina (*Soft Sensor for continuous product quality estimation in crude distillation unit*) donde utilizaron redes neuronales de tipo MLP (*Multilayer Perceptron*) y RBN (*Radial Basis Network*) para la construcción de un *soft sensor* que predijera el RVP (Reid Vapor Pressure) de la gasolina estabilizada con buenos resultados (Error absoluto promedio <0.06 y Coeficiente de correlación >0.8); en el presente trabajo se construyeron con ayuda de la herramienta NNTOOL los siguientes tipos redes neuronales para cada uno de los parámetros a predecir PFE del Jet A y T95 del ACPM:

- *Multilayer perceptron feed-forward backpropagation (MLPFFB).*
- *Multilayer perceptron cascade-forward backpropagation (MLPCFB).*
- *Radial basis (RB) exact fit.*
- *Radial basis (RB) fewer neurons.*
- *Perceptron (P).*

De acuerdo a lo descrito anteriormente en la siguiente tabla se resumen todos los tipos de redes neuronales que se construyeron para predecir de manera independiente el PFE del Jet A y T95 del ACPM utilizando las herramientas NFTOOL y NNTOOL donde para el caso de las redes tipo multicapa se evaluaron diferentes funciones de transferencia en la capa oculta y de salida, así como también diferentes números de capas ocultas y neuronas. En total se construyeron 52 redes neuronales de las cuales 26 son para predecir el parámetro del PFE del Jet A y las otras 26 para predecir la T95 del ACPM. De las 56 redes 44 son tipo multicapa, 4 tipo perceptron y 4 tipo base radial.

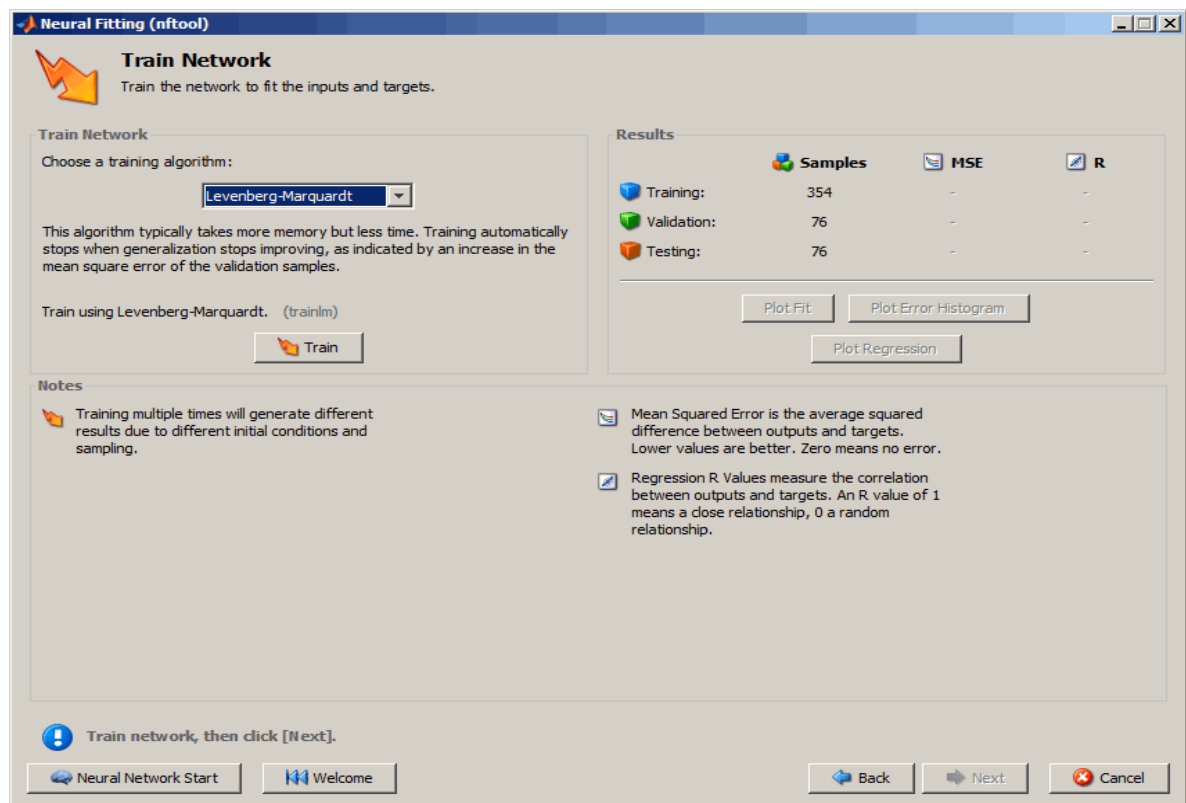
Tabla 9. Redes Neuronales Construidas para predecir PFE del Jet A y T95 del ACPM

#Red	Tipo de Red	Herramienta	# de Capas	# de Neuronas Capa Oculta	F. de Trasf. Capas Ocultas	F- de Trasf. Capa de Salida	Variable de Salida
1	MLPFF	NFTOOL	2	10	Tan-Sigmoid (Tansig)	Linear (Purelin)	PFE JET A
2	MLPFF	NFTOOL	2	10	Tan-Sigmoid (Tansig)	Linear (Purelin)	T95 ACPM
3	MLPFF	NFTOOL	2	13	Tan-Sigmoid (Tansig)	Linear (Purelin)	PFE JET A
4	MLPFF	NFTOOL	2	15	Tan-Sigmoid (Tansig)	Linear (Purelin)	T95 ACPM
5	MLPFF	NNTOOL	2	10	Tan-Sigmoid (Tansig)	Linear (Purelin)	PFE JET A
6	MLPFF	NNTOOL	2	10	Tan-Sigmoid (Tansig)	Linear (Purelin)	T95 ACPM
7	MLPFF	NNTOOL	2	10	Log-Sigmoid (Logsig)	Linear (Purelin)	PFE JET A
8	MLPFF	NNTOOL	2	10	Log-Sigmoid (Logsig)	Linear (Purelin)	T95 ACPM
9	MLPFF	NNTOOL	2	10	Linear (Purelin)	Linear (Purelin)	PFE JET A
10	MLPFF	NNTOOL	2	10	Linear (Purelin)	Linear (Purelin)	T95 ACPM
11	MLPFF	NNTOOL	2	10	Tan-Sigmoid (Tansig)	Tan-Sigmoid (Tansig)	PFE JET A
12	MLPFF	NNTOOL	2	10	Tan-Sigmoid (Tansig)	Tan-Sigmoid (Tansig)	T95 ACPM
13	MLPFF	NNTOOL	2	10	Log-Sigmoid (Logsig)	Tan-Sigmoid (Tansig)	PFE JET A
14	MLPFF	NNTOOL	2	10	Log-Sigmoid (Logsig)	Tan-Sigmoid (Tansig)	T95 ACPM
15	MLPFF	NNTOOL	2	10	Linear (Purelin)	Tan-Sigmoid (Tansig)	PFE JET A
16	MLPFF	NNTOOL	2	10	Linear (Purelin)	Tan-Sigmoid (Tansig)	T95 ACPM
17	MLPFF	NNTOOL	2	10	Tan-Sigmoid (Tansig)	Log-Sigmoid (Logsig)	PFE JET A
18	MLPFF	NNTOOL	2	10	Tan-Sigmoid (Tansig)	Log-Sigmoid (Logsig)	T95 ACPM
19	MLPFF	NNTOOL	2	10	Log-Sigmoid (Logsig)	Log-Sigmoid (Logsig)	PFE JET A
20	MLPFF	NNTOOL	2	10	Log-Sigmoid (Logsig)	Log-Sigmoid (Logsig)	T95 ACPM
21	MLPFF	NNTOOL	2	10	Linear (Purelin)	Log-Sigmoid (Logsig)	PFE JET A
22	MLPFF	NNTOOL	2	10	Linear (Purelin)	Log-Sigmoid (Logsig)	T95 ACPM
23	MLPFF	NNTOOL	4	13	Tan-Sigmoid (Tansig)	Linear (Purelin)	PFE JET A
24	MLPFF	NNTOOL	4	15	Tan-Sigmoid (Tansig)	Linear (Purelin)	T95 ACPM
25	MLPCF	NNTOOL	2	10	Tan-Sigmoid (Tansig)	Linear (Purelin)	PFE JET A
26	MLPCF	NNTOOL	2	10	Tan-Sigmoid (Tansig)	Linear (Purelin)	T95 ACPM
27	MLPCF	NNTOOL	2	10	Log-Sigmoid (Logsig)	Linear (Purelin)	PFE JET A
28	MLPCF	NNTOOL	2	10	Log-Sigmoid (Logsig)	Linear (Purelin)	T95 ACPM
29	MLPCF	NNTOOL	2	10	Linear (Purelin)	Linear (Purelin)	PFE JET A
30	MLPCF	NNTOOL	2	10	Linear (Purelin)	Linear (Purelin)	T95 ACPM
31	MLPCF	NNTOOL	2	10	Tan-Sigmoid (Tansig)	Tan-Sigmoid (Tansig)	PFE JET A
32	MLPCF	NNTOOL	2	10	Tan-Sigmoid (Tansig)	Tan-Sigmoid (Tansig)	T95 ACPM
33	MLPCF	NNTOOL	2	10	Log-Sigmoid (Logsig)	Tan-Sigmoid (Tansig)	PFE JET A
34	MLPCF	NNTOOL	2	10	Log-Sigmoid (Logsig)	Tan-Sigmoid (Tansig)	T95 ACPM
35	MLPCF	NNTOOL	2	10	Linear (Purelin)	Tan-Sigmoid (Tansig)	PFE JET A
36	MLPCF	NNTOOL	2	10	Linear (Purelin)	Tan-Sigmoid (Tansig)	T95 ACPM
37	MLPCF	NNTOOL	2	10	Tan-Sigmoid (Tansig)	Log-Sigmoid (Logsig)	PFE JET A
38	MLPCF	NNTOOL	2	10	Tan-Sigmoid (Tansig)	Log-Sigmoid (Logsig)	T95 ACPM
39	MLPCF	NNTOOL	2	10	Log-Sigmoid (Logsig)	Log-Sigmoid (Logsig)	PFE JET A
40	MLPCF	NNTOOL	2	10	Log-Sigmoid (Logsig)	Log-Sigmoid (Logsig)	T95 ACPM
41	MLPCF	NNTOOL	2	10	Linear (Purelin)	Log-Sigmoid (Logsig)	PFE JET A
42	MLPCF	NNTOOL	2	10	Linear (Purelin)	Log-Sigmoid (Logsig)	T95 ACPM
43	MLPCF	NNTOOL	4	13	Tan-Sigmoid (Tansig)	Linear (Purelin)	PFE JET A
44	MLPCF	NNTOOL	4	15	Tan-Sigmoid (Tansig)	Linear (Purelin)	T95 ACPM
45	P	NNTOOL	NA	NA		Hardlim	PFE JET A
46	P	NNTOOL	NA	NA		Hardlim	T95 ACPM
47	P	NNTOOL	NA	NA		Hardlims	PFE JET A
48	P	NNTOOL	NA	NA		Hardlims	T95 ACPM
49	RB(<i>exact fit</i>)	NNTOOL	NA	NA		Radbas	PFE JET A
50	RB(<i>exact fit</i>)	NNTOOL	NA	NA		Radbas	T95 ACPM
51	RB (<i>fewer neurons</i>)	NNTOOL	NA	NA		Radbas	PFE JET A
52	RB (<i>fewer neurons</i>)	NNTOOL	NA	NA		Radbas	T95 ACPM

Como se describirá más adelante en la etapa de validación y prueba del modelo, a las redes neuronales construidas se les evalúo su desempeño definiendo cuál de estas presenta la mejor predicción

5.3.2. Entrenamiento de las redes neuronales. Para el entrenamiento de las redes neuronales construidas también se utilizaron las herramientas NFTOOL y NNTOOL, en la herramienta NFTOOL se tiene la opción de utilizar dos funciones de entrenamiento (**Ver figura 33**) la *Levenberg-Marquart backpropagation (trainlm)* o la *scaled conjugate gradient backpropagation (trainscg)* dependiendo de la capacidad de memoria del procesador.

Figura 33. Herramienta NFTOOL entrenamiento de la red.



En la herramienta NNTOOL para las redes neuronales tipo multicapa se tienen las siguientes opciones para el entrenamiento de la red:

Tabla 10. Funciones de Entrenamiento para redes neuronales multicapa herramienta NNTOOL

Function	Algorithm
trainlm	Levenberg-Marquardt
trainbr	Bayesian Regularization
trainbfg	BFGS Quasi-Newton
trainrp	Resilient Backpropagation
trainscg	Scaled Conjugate Gradient
traincgb	Conjugate Gradient with Powell/Beale Restarts
traincgf	Fletcher-Powell Conjugate Gradient
traincgp	Polak-Ribière Conjugate Gradient
trainoss	One Step Secant
traingdx	Variable Learning Rate Gradient Descent
traingdm	Gradient Descent with Momentum
traingd	Gradient Descent

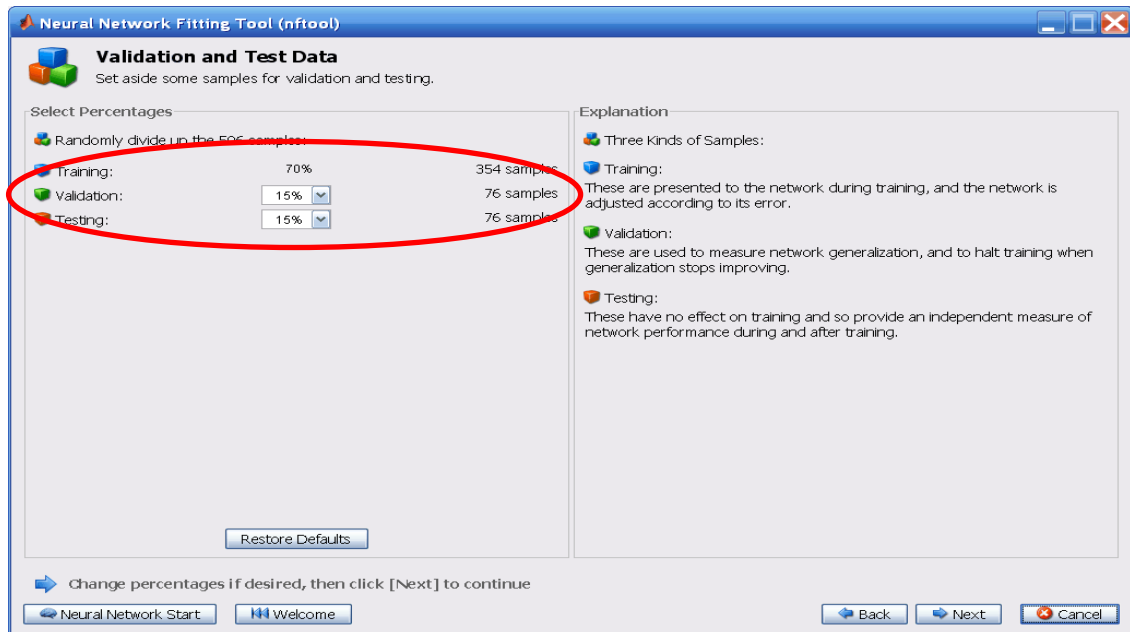
En el caso de la red neuronal tipo *perceptron* en la herramienta NNTOOL se tiene como única función de entrenamiento llamada *trainc* (*cyclical weight/bias rule*) donde se ejecuta de manera cíclica una función de aprendizaje llamada *learnp* (Ver figura 30).

En el presente trabajo se evaluaron dos tipos de funciones de entrenamiento para las redes construidas tipo multicapa: La *Levenberg-Marquart backpropagation* (*trainlm*) y la *scaled conjugate gradient backpropagation* (*trainscg*) teniendo en cuenta que de acuerdo a estudios anteriores estos algoritmos de entrenamiento tienen el mejor desempeño (tiempo de entrenamiento y predicción) para problemas de funciones de aproximación (o regresiones no lineales)¹³¹, la evaluación del desempeño de predicción de estos dos métodos de entrenamiento se realizó utilizando los parámetros coeficiente de correlación R y el promedio de los errores al cuadrado los cuales se explicaran con más detalle en la etapa de

¹³¹ J. HILERA y V. MARTINEZ, Redes Neuronales Artificiales Fundamentos, Modelos y Aplicaciones, Addison-Wesley Iberoamerica, Cap 3, 1995

validación y prueba de las redes neuronales. Los datos utilizados para el entrenamiento de las redes en las herramientas NFTOOL (Ver Figura 34) y NNTOOL por default son el 70% de los datos introducidos (*inputs-targets*) para la construcción de la red elegidos al azar.

Figura 34. Herramienta NFTOOL distribución de datos para entrenamiento.



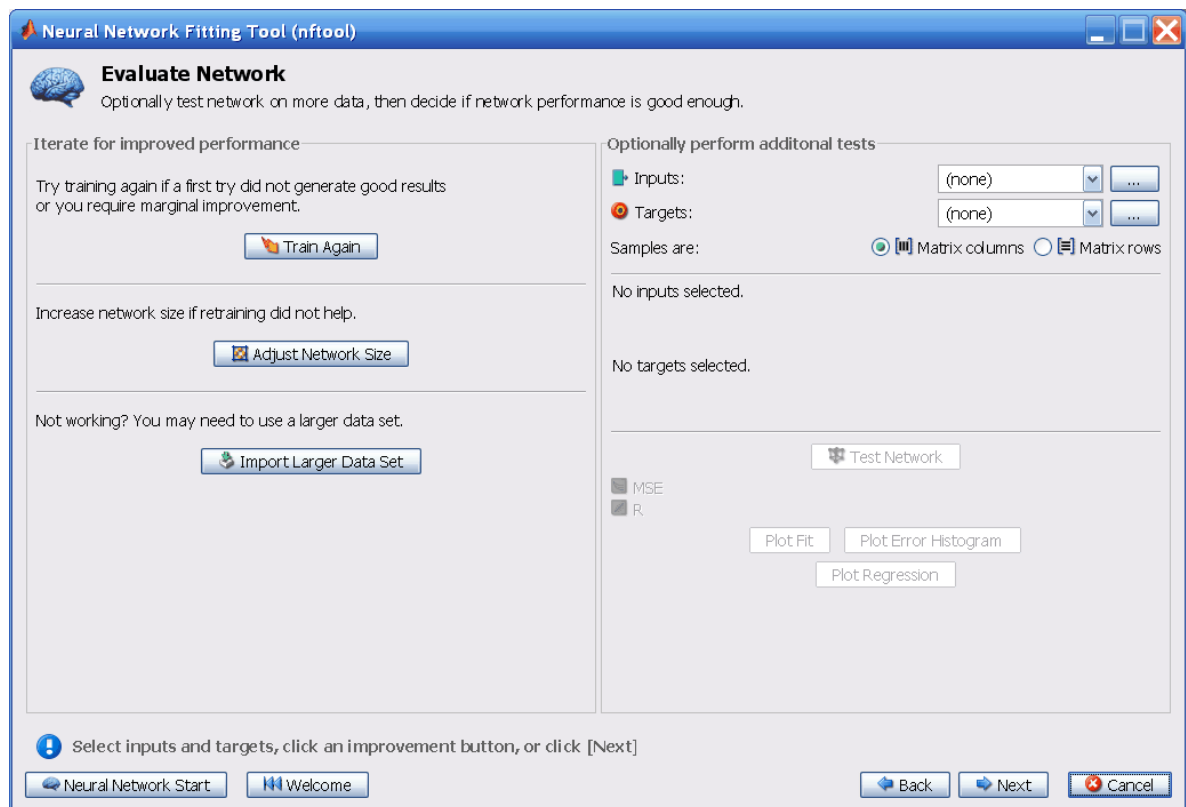
5.3.3. Validación y prueba de las redes neuronales. Para la validación de los diferentes tipos de redes neuronales construidas y entrenadas se utilizó como parámetro el coeficiente R que mide la correlación entre los datos obtenidos por el modelo (*Outputs*) y los datos reales (*Targets*). Un valor de $R = 1.0$ indica que el modelo del *soft sensor* tiene una capacidad de predicción perfecta donde los datos obtenidos del modelo *outputs* son iguales a los datos reales *targets*, valores de R cercanos a 0.0 indican que el modelo no es el adecuado para predicción requerida.

El otro parámetro utilizado es el promedio del error al cuadrado MSE (*Mean Squared Error*) donde el error es la diferencia en los datos obtenidos del modelo

outputs y los datos reales *targets*. Bajos valores en el MSE indican que el modelo tiene una aproximación adecuada.

En las herramientas NFTOOL y NNTOOL los parámetros R y MSE para las redes tipo multicapa están entre las opciones para la validación y prueba de las redes neuronales construidas (**Ver Figuras 33 y 35**), los datos utilizados para la validación y prueba son por default el 15% (**Ver Figura 34**) de los datos recopilados introducidos para la construcción de las redes elegidos al azar. Las herramienta NFTOOL y NNTOOL tienen la opción de hacer una prueba adicional simulando la red neuronal (**Ver Figura 35**) lo cual se llevó a cabo utilizando los datos más recientes recopilados (Mayo a Octubre de 2015).

Figura 35. Herramienta NFTOOL prueba adicional.



Para el caso de las redes neuronales tipo RB (*Radial Basis*) y P (*Perceptron*) la herramienta NNTOOL no tiene la opción de realizar validación utilizando los parámetros R y MSE, sin embargo fue posible realizar una prueba simulando las redes neuronales lo cual se llevó a cabo utilizando los datos recopilados más recientes (Mayo a Octubre de 2015) obteniendo el error (*Targets-Outputs*) con lo cual se calculó el R y MSE en el software Excel.

En resumen en la etapa de entrenamiento, validación y prueba de las redes neuronales construidas, se utilizaron como parámetros el coeficiente de correlación R y el MSE (*Mean Squared Error*) para evaluar su desempeño para la predicción de las variables PFE del Jet y T95 del ACPM.

6. RESULTADOS

6.1. RECOLECCIÓN Y PRE-PROCESAMIENTO DE DATOS HISTÓRICOS DE PLANTA Y LABORATORIO.

En las **Figuras 36 a 57** se muestra el comportamiento observado en el periodo comprendido entre agosto de 2013 y octubre de 2015, de las variables dependientes (Y1 y Y2) y de las variables independientes (X1 a x20)

Figura 36. Tendencia Punto Final de Ebullición (PFE) JET-A (Y1)

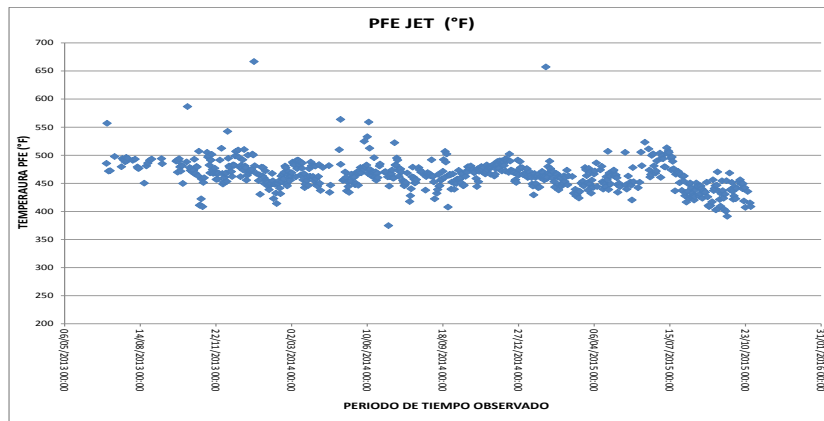




Figura 37. Tendencia T95%Vol de Recobrado ACPM (Y2)



En la **figura 36**, la variable dependiente Y1 (PFE de Jet) muestra una dispersión moderada con valores que se distribuyen entre 425°F y 500°F, siendo valores típicos para este parámetro. En el periodo evaluado se observan datos atípicos con valores de 370°F y 665°F los cuales se pueden atribuir a disturbios operacionales y/o muestreo inadecuado.

Respecto a la **figura 37**, correspondiente a la variable Y2 (T95 del ACPM) se observa también una dispersión moderada con valores normales entre 620°F y 710°F. Igualmente se observa algunos datos atípicos bajos, entre 580°F y 490°F asociados a muestreos inadecuados o disturbios en la operación.


Figura 38. Tendencia Temperatura Salida Crudo H150 (X1)



Respecto a **figura 38**, correspondiente a la tendencia de la variable de entrada X1 (temperatura salida crudo H150) se aprecia una dispersión significativa alta asociada con los cambios de carga de crudo de la unidad. También se observan


valores hasta de 710°F cuando se procesan crudos con gravedad API menor a 28 y temperaturas entre 560°F y 650°F para crudos con gravedad API mayor 30 (**ver figura 57**). De acuerdo con periodo observado, no se identifican datos atípicos para esta variable pues los valores se encuentran entre las ventanas operativas del H150 de 560°F a 730°F.

Figura 39. Tendencia Temperatura Salida Reflujo Inferior T150 (X2)




El comportamiento de la variable X2 (temperatura salida reflujo inferior T150), muestra una alta dispersión con valores alejados del promedio, este comportamiento está asociado con los cambios de composición de carga a la unidad. Los datos se encuentran dentro los valores normales de operación para esta variable, los cuales están entre 650°F a 510°F.

Figura 40. Tendencia Temperatura Entrada Reflujo Inferior T150 (X3)



La X3 correspondiente a la temperatura de entrada del reflujo inferior T150, de acuerdo con la **figura 40** su comportamiento una dispersión significativa en los datos asociados a los cambios de carga de la U150, con valores dentro los límites normales de operación (530°F a 350°F) sin datos atípicos registrables.


Figura 41. Tendencia Flujo Reflujo Inferior T150 (X4)



Para la variable de entrada X4 (flujo reflujo inferior T150), se aprecia en la **figura 41** una dispersión considerable con valores entre 4 500BPD y 9 500BPD; siendo


valores normales de operación de acuerdo a las ventanas de flujo (13 000 BPD - 4 000 BPD) para el sistema de bombeo asociado.

Figura 42. Tendencia Temperatura Salida Reflujo Medio T150 (X5)




De acuerdo a lo mostrado por la **figura 42** la variable temperatura salida reflujo medio T150 (X5) presenta una dispersión moderada con valores normales de operación entre 480°F y 370. No se observan valores atípicos.

Figura 43. Tendencia Temperatura Entrada Reflujo Medio T150 (X6)




La variable temperatura de entrada de reflujo medio de la T150 (X7) muestra una dispersión significativa, atribuible a los cambios de composición del crudo cargado a la unidad; sin embargo los valores están dentro el rango normal de operación entre 380°F y 260°F.

Figura 44. Tendencia Temperatura de Cima T150 (X7)




Según la **figura 44** la temperatura de cima de la T204 (X7) muestra una dispersión baja con valores dentro de la ventana de operación establecida (>260°F), sin datos atípicos. Los valores alejados al promedio obedecen a los cambios de composición en el crudo cargado y/o disturbios operacionales.

Figura 45. Tendencia Presión de Cima T150 (X8)




La **figura 45** muestra para la variable presión de cima T150 (X8) una dispersión considerable, con valores por encima de la operación normal de 14 psig máximo; sin embargo no son considerados datos atípicos pues están asociados a inestabilidades operacionales que hacen parte a la dinámica del proceso.

Figura 46. Tendencia Flujo Reflujo de Cima T150 (X9).



Según la **figura 47** la variable de entrada X10 (flujo reflujos de cima T150) muestra una dispersión significativa, se encuentran algunos datos alejados del promedio pero no se consideran atípicos pues se encuentran dentro de los valores normales de operación entre 11 000BPD y 3 000BPD. La dispersión de los datos se asocia al cambio en la composición del crudo carga a la U150.

Figura 47. Tendencia Temperatura Salida ACPM T150 (X10)



Las temperaturas de extracción del Jet y ACPM en la T150 (**ver figuras 47 y 48**) muestran una dispersión significativa, los valores están dentro los límites de operación establecidos con datos para el caso del Jet entre 400°F y 340°F, y para el ACPM entre 540°F y 460°F; las variaciones fuertes durante el periodo obedecen a los cambio en la composición del crudo cargado a la unidad.

Figura 48. Tendencia Temperatura Salida Jet-A T150 (X11)






Figura 49. Tendencia Flujo Producción de Jet-A T150 (X12)



El flujo de producción de Jet (X12) muestra una alta dispersión con valores entre 6 000BPD y 1 800 BPD vs 7 800 BPD y 1 800 BPD valores de las ventanas de operación del sistema de bombeo asociado; la alta dispersión se debe a los cambios en la composición del crudo cargado a la unidad. Para esta variable se observan algunos datos atípicos con valores de 0 BPD o “Bad Inputs” asociados a disturbios operaciones o falla en el transmisor de flujo.

Figura 50. Tendencia Flujo Producción de ACPM T150 (X13)



El flujo de producción de ACPM al igual que el flujo del Jet, presenta alta dispersión con valores entre 8 500 BPD y 2 000 BPD que se encuentran dentro las ventanas de flujo para sistema de bombeo asociado (8 800BPD y 3 000 BPD), la la dispersión puede estar asociada con los cambios de composición de crudo cargado en la unidad. Se observan datos atípicos relacionados con disturbios operacionales y errores en la medición.

Figura 51. Tendencia Flujo Vapor al Fondo T150 (X14)




Figura 52. Tendencia Flujo Vapor al Fondo T151A (X15)




Figura 53. Tendencia Flujo Vapor al Fondo T151B (X16)






Figura 54. Tendencia Flujo Vapor al Fondo T151C (X17)




En las **figuras 51 - 54** se observa el comportamiento de las variables independientes X14 - X17 que hacen referencia al flujo de vapor al fondo de la T150 y T151ABC, encontrándose una alta dispersión de los datos, asociados con errores en la medición y ajustes operacionales. Por otro lado se observa especialmente para el caso de los flujos de vapor a las despojadoras T151ABC un significativo número de datos atípicos que son atribuibles a mediciones erróneas.

Figura 55. Presión D150 (X18)




La presión del tambor de cima D150 variable X18 de acuerdo con la figura 55 muestra un comportamiento con una dispersión moderada con valores de presión entre 12psig y 6psig; los cuales están dentro del límite de operación normal de 14psig Max. Se aprecian valores atípicos asociados a disturbios operacionales con valores de hasta 0psig.

Figura 56. Flujo Reflujo Medio T150 (X19)



En la **figura 56** se muestra el comportamiento durante el periodo de observación del flujo de reflujo medio de la T150, mostrando una dispersión considerable que se atribuye a los cambios de composición en la carga de la unidad, los valores oscilan entre 18 000 BPD y 8 500 BPD los cuales se encuentran dentro de las ventanas (32 000 BPD a 8 400 BPD) de flujo del sistema de bombeo asociado. Respecto a datos atípicos se pueden evidenciar valores por debajo del flujo mínimo, llegando hasta valores de 0 BPD debido a fallas en la medición y/o disturbios operacionales.

Figura 57. Tendencia Gravedad API Crudo (X20)



En la **figura 57** tal y como se describe en el planteamiento del problema del presente trabajo de aplicación, se observa una alta variabilidad en la composición del crudo cargado a la unidad U150 que a su vez influye en el comportamiento de todas las variables (dependientes e independientes) anteriormente analizadas; por tanto esta variable de entrada es fundamental para la construcción del modelo. La gravedad API en el crudo cargado para el periodo evaluado se distribuye entre 45 y 25, adicionalmente no se observan datos atípicos teniendo en cuenta que los valores de gravedad API se encuentran dentro los valores esperados para los crudos cargados en la U150.

En la siguiente tabla se muestra los valores promedio, desviación estándar y valores mínimos y máximos de todas las variables:

Tabla 11. Estadístico de Cada Variable.

	Y1	Y2	X1	X2	X3	X4	X5	X6	X7	X8	X9	X10	X11	X12	X13	X14	X15	X16	X17	X18	X19	X20
PRIOMEDIO	464.80	646.97	611.32	561.49	406.96	6173.46	415.88	301.81	269.31	9.80	6913.70	494.27	369.85	3929.02	5905.45	3960.78	401.64	574.49	323.39	8.04	15376.20	38.15
DESVIACION ESTD	26.25	22.01	26.74	21.28	15.51	569.84	17.96	15.41	3.02	1.48	833.80	16.95	9.90	1114.33	976.10	778.63	280.65	430.84	381.14	1.37	2092.25	3.21
MIN	374.70	487.90	566.07	510.68	356.74	5003.41	360.01	263.35	248.80	5.16	5072.60	451.42	332.69	0.13	2535.18	491.46	0.12	1.30	-1.77	4.31	8857.06	22.80
MAX	666.70	711.70	720.63	646.42	475.99	9539.50	485.99	376.25	287.17	15.42	11482.43	557.97	406.54	6270.66	9017.77	4887.04	1357.91	2480.82	2082.25	12.94	18439.83	47.30


Donde :

Y1 : PFE JET, **Y2**: T95 ACPM, **X1**: Temperatura Salida Crudo H150, **X2**: Temperatura Salida Reflujo Inferior T150, **X3**: Temperatura Entrada Reflujo Inferior T150, **X4**: Flujo Reflujo Inferio T150, **X5**: Temperatura Salida Reflujo Medio, **X6**: Temperatura Entrada Reflujo Medio, **X7**: Temperatura Cima T150, **X8**: Presion Cima T250, **X9**: Flujo Reflujo de Cima T150, **X10**: Temperatura Salida ACPM, **X11**: Temperatura Salida Jet, **X12**: Flujo Producción ACPM, **X13**: Flujo Produccion ACPM, **X14**: Flujo Vapor al Fondo T150, **X15**: Flujo Vapor al Fondos T151A, **X16**: Flujo Vapor al Fondo T151B, **X17**: Flujo Vapor al Fondo T151C, **X18**: Presion D150, **X19**: Reflujo Medio T150, **X20**: Gravedad API Crudo Carga.

De acuerdo con los gráficos y los valores de desviación estándar, las variables que muestran una mayor variabilidad (Dispersión) son las llamadas X12, X13, X15, X16 y X17 que corresponden a la producción de Jet (Kero/JP), producción de ACPM, vapor al fondo T151A, B y C respectivamente. Adicionalmente los valores mínimos para estas variables excepto X13 (Producción de ACPM) presentan valores fuera del rango normal de operación como se mostró preliminarmente en el análisis de tendencias, por tanto fueron descartadas las muestras u observaciones correspondientes a estos datos para la definición de las variables de entrada al modelo. Así mismo se descartaron aquellas muestras cuyos valores mostraban error en la medición “*Bad Input*” como fue el caso de las variables vapor al fondo de la T150 y T151C.


Adicionalmente, con el objetivo de identificar datos atípicos en las variables que puedan afectar el desarrollo del modelo para el *soft sensor*, se utilizó el método de diagnóstico de residuos estandarizados. Este método de diagnóstico considera que las observaciones con un valor absoluto en los residuales estandarizados, $\sigma > \pm 2$, se consideran valores atípicos o “*outliers*”. A continuación se muestran los resultados de este análisis:

Figura 58. Residuos Estándar Pronostico PFE Jet-A



De acuerdo al gráfico de análisis residual para la matriz de datos (Tabla 3) de la variable dependiente punto final de ebullición (PFE) Jet-A se identificaron 18 valores atípicos que corresponden a las muestras u observaciones 2, 35, 49, 50, 51, 82, 116, 121, 203, 230, 233, 235, 253, 277, 278, 317, 318 y 436.

Figura 59. Residuos Estándar Pronostico T95 ACPM



En el gráfico de residuales estandarizados para la matriz de datos de la T95 del ACPM (Tabla 4) se identificaron 17 observaciones atípicas: 44, 52, 54, 74, 78, 82, 117, 139, 143, 202, 210, 222, 223, 238, 243, 393 y 498.

En resumen teniendo en cuenta las observaciones descartadas por tener valores mínimos en las variables independientes fuera del rango normal de operación, mediciones erróneas “*Bad Input*” y valores atípicos identificados por el análisis residual, las matrices de datos para la variables dependientes PFE Jet-A (Y1) y T95 del ACPM (Y2) con su respectivas variables independientes, condiciones de operación y calidad de la carga (X1, X2...X20), quedaron con un total de observaciones de 626 y 594 respectivamente luego de la depuración.

6.2. DEFINICIÓN DE LAS VARIABLES DE ENTRADA AL MODELO Y SUS INTERVALOS

6.2.1. Matriz dinámica del control avanzado de proceso U150. En la tabla 11 se observan las variables de proceso manipuladas de la U150. De acuerdo con la tabla, las variables que tienen un efecto directo sobre la variable controlada (punto final de ebullición de Jet – A) son la presión de cima T150, temperatura de cima T150, producción de Jet-A, y la variable *feed forward* vapor de despojo T150 (T150JET_PFE). Para el caso del Punto Final de Ebullición ACPM (T150ACPM_PFE) las variables manipuladas y *feed forward* que tienen efecto directo son las mismas que para el PFE del Jet-A incluyendo la producción de ACPM y la variable error en la predicción (TC15001_IPE) respectivamente, lo cual puede ser extrapolado para el parámetro de T95 del ACPM pues junto con el PFE tienen una relación directa por ser dos puntos muy cercanos en la curva de destilación ASTM D86 como se mostró en el marco teórico.

Tabla 12. Matriz Dinámica Control Avanzado de Proceso U150.

								CONTROLADAS (RESTRINGIDAS O DEPENDIENTES)					
								T150JET_10	T150JET_PFE	T150ACPM_PFE	T150_DP	LIC15003	LIC15004
VARIABLES MANIPULADAS		Típico Mov	Unidad	LPCost	Max Move	Move Supres	SS Step	° F	° F	° F	PSIG	%	%
PRC15001_S	Presion T-150	1	PSIG	2.7	0.5	10	3	↓ -6.06656	↓ -2	↓ -6	↓ -0.112756		
TIC15002_S	Temperatura Cima T-150	1	° F	-1.762	2	5	20	↑ 1.23962	↑ 1	↑ 1.54	↓ -0.0168		
FRC15003_S	Produccion de Jet-A1	100	BPD	-0.608	300	2	3000		↑ 1.11425	↑ 2.2	↓ -0.024	↑ 0.41	
FRC15004_S	Produccion de Diesel	100	BPD	-0.876	300	2	3000			↑ 2.33333	↓ -0.0184683		↑ 0.4923
FIC15005_S	Produccion de Goa	100	BPD	2.384	100	2	1000						
FRC15006_S	Reflujo Medio T-150	100	BPD	0.001	400	2	4000						
FRC15007_S	Reflujo Inferior T-150	100	BPD	0.001	400	2	4000						
VARIABLES FFW													
FC15020_S	Vapor despojo T-150	100	Lb/Hr						↓ -0.121964	↓ -0.319024	↑ 0.0183612		
TC15001_IPE	Error de Prediccion	2	° F							↓ -1.372616	↓ -0.0414		
PC20201_M	Presion D-245		PSIG										

Fuente: ECOPEPETROL S.A. Ingenieros Control Avanzado, Gerencia Refinería de Barrancabermeja, Matriz Dinamica Control Avanzado de Proceso U150,, 2009.

La variable manipulada que tiene mayor impacto sobre el PFE del Jet-A y ACPM según la matriz dinámica es la presión de cima de la T150 y la de menor efecto es el vapor de despojo a la T150. El impacto sobre las variables controladas está representado por la magnitud del cambio en el valor de la variable que puede ser negativo o positivo (Aumentar o Disminuir) luego de un movimiento positivo de la variable manipulada. De acuerdo con lo anterior, un incremento de 1psig en la presión de cima de la T150 disminuye 2°F el PFE del ACPM y 6°F el PFE.

En resumen de acuerdo con la matriz dinámica del control avanzado de proceso de la U150 las variables presión T150, temperatura cima T150, producción de Jet, producción de ACPM (diésel) y vapor al fondo de la T150 pueden ser consideradas como variables de entrada para el modelo de predicción del PFE del Jet y T95%vol del ACPM.

6.2.2. Diagrama de relación de parámetros en destilación. De acuerdo con el diagrama de relación de parámetros para la destilación (**Ver Figura 60**) un aumento en el perfil de temperatura en la torre de destilación (temperatura de cima, fondo y salida de productos laterales) a una presión constante genera que los productos tengan una composición más pesada; es decir hay un aumento en los puntos finales de ebullición (PFE) y T95%vol de recobrado. Un aumento en el perfil de temperatura en la torre se puede generar por una mayor temperatura en la carga (mayor temperatura de salida del horno o rehervidor) o por una disminución en los reflujos (cima, medio o inferior) en la torre.


Para el caso de la presión, un aumento en esta variable (presión de cima de la torre) genera que los productos tengan una composición más liviana es decir una disminución en los PFE y T95%vol

Por último si la composición en la carga se hace más pesada genera que los productos tengan también una composición más pesada aumentado el PFE y T95%vol.

En resumen de acuerdo con la relación de parámetros para el proceso de destilación, las variables que más influyen sobre la calidad de los productos PFE y T95%vol del Jet-A y ACPM serían las siguientes:

- Temperatura Salida H150
- Temperatura Salida Reflujo Inferior
- Temperatura Entrada Reflujo Inferior
- Temperatura Salida Reflujo Medio
- Temperatura Entrada Reflujo Medio
- Temperatura Cima T150
- Temperatura Salida ACPM
- Temperatura Salida JET
- Reflujo de Cima T150
- Reflujo Medio T150
- Reflujo Inferior T150
- Presión Cima T150
- Composición de la Carga de Crudo medida en Gravedad API.

Figura 60. Diagrama de Relación de Parámetros para Destilación. [14]



Fuente: GRB-ECOPETROL S.A., Manual de descripción de procesos de la unidad de crudo U150 MDPU, RWD, Cap 3 - 6, 2008.

6.2.3. Experiencia operativa. De acuerdo con la experiencia operativa del personal de la GRB, el tablerista encargado de la U150 emplea para controlar los valores de PFE (Jet – A) y T95%vol (Diesel), las siguientes variables: el flujo de producción de Jet, flujo de producción de ACPM, temperatura de salida de Jet, temperatura de salida de ACPM y temperatura de salida del horno H150.

6.2.4. Análisis de regresión lineal múltiple. Considerando los criterios expuestos en las secciones 6.2.1 a 6.2.3, se procedió a realizar un análisis de regresión lineal múltiple a las variables independientes pre-definidas. El objetivo del análisis fue el de identificar las variables independientes que tienen un mayor efecto a la hora de explicar el comportamiento de las variables dependientes (PFE y T95%vol). El criterio de significancia solo incorpora al modelo de regresión aquellas variables que contribuyen de manera significativa al ajuste del modelo [21], lo cual se cumple si el coeficiente de correlación parcial es significativamente diferente de cero con una probabilidad de entrada menor a 0.05.

A continuación se muestran los resultados obtenidos para cada una de las variables dependientes (PFE y T95%vol)

Tabla 13. Estadísticas Regresión Modelo para PFE Jet-A

<i>Estadísticas de la regresión</i>	
Coefficiente de correlación múltiple	0.805
Coefficiente de determinación R ²	0.648
R ² ajustado	0.638
Error típico	12.962
Observaciones	626

Tabla 14. Coeficientes y Probabilidad Variables Modelo PFE Jet-A

Variables	TAG	Coeficientes	Error típico	Probabilidad (significancia)	
X1	SALIDA CRUDO H150	u150-TRCT15001	-0.079	0.063	0.212
X2	SALIDA REF INF	u150-ti150182	-0.248	0.062	7.55E-05
X3	REF.INF.T150	U150-TICT15004	-0.039	0.056	0.491
X4	REF INF T150	u150-frCT15007	-0.001	0.001	0.266
X5	SALIDA REF MED	u150-ti150181	0.452	0.111	5.35E-05
X6	REF.MED.T150	U150-TICT15003	-0.207	0.071	0.004
X7	CIMA T150	U150-TICT15002	-0.040	0.205	0.847
X8	PRESION .CIMA T150	u150-PIT15020	-3.357	0.412	2.11E-15
X9	REF CIMA T150	u150-frCT15002	0.002	0.001	0.079
X10	SALIDA ACPM	u150-ti150114	0.381	0.123	0.002
X11	SALIDA JP/K	u150-ti150112	0.613	0.129	2.57E-06
X12	KERO/JP	u150-frCT15003	0.000	0.001	0.734
X13	ACPM	u150-frCT15004	-0.005	0.001	1.298E-05
X14	VAP FDO T150	u150-flT15020	0.002	0.001	0.051
X19	REF MEDIO T 150	U150-FRCT15006	0.001	0.000	0.118
X20	COMPOSICION CR	API	0.461	0.226	0.042

Según los resultados las variables que cumplen con los criterios de significancia y por tanto se seleccionaron como variables de entrada para el desarrollo del modelo del *soft sensor* para la predicción del parámetro de punto final de ebullición del Jet-A son las siguientes: X2 (Temperatura de Salida Reflujo Inferior), X5 (Temperatura de Salida Reflujo Medio), X6 (Temperatura Entrada Reflujo Medio), X8 (Presión Cima T150), X10 (Temperatura Salida ACPM), X11 (Temperatura Salida Jet-A), X13 (Flujo Producción de ACPM), X14 (Flujo Vapor al Fondo T150) y X20 (Gravedad API Crudo Carga)

Tabla 15. Estadísticas Regresión Modelo para T95 ACPM

<i>Estadísticas de la regresión</i>	
Coeficiente de correlación múltiple	0.821
Coeficiente de determinación R^2	0.675
R^2 ajustado	0.666
Error típico	11.392
Observaciones	594

Tabla 16. Coeficientes y Probabilidad Variables Modelo T95 ACPM

Variables	TAG	Coeficientes	Error típico	Probabilidad (significancia)	
X1	SALIDA CRUDO H150	u150-TRCT15001	0.060	0.057	0.297
X2	SALIDA REF INF	u150-ti150182	0.081	0.061	0.190
X3	REF.INF.T150	U150-TICT15004	0.105	0.051	0.039
X4	REF INF T150	u150-frCT15007	-0.003	0.001	0.018
X5	SALIDA REF MED	u150-ti150181	0.533	0.103	2.89E-07
X6	REF.MED.T150	U150-TICT15003	-0.526	0.064	1.45E-15
X7	CIMA T150	U150-TICT15002	-0.849	0.190	9.90E.06
X8	PRESION .CIMA T150	u150-PIT15020	-2.226	0.377	6.18E-09
X9	REF CIMA T150	u150-frCT15002	0.001	0.001	0.219
X10	SALIDA ACPM	u150-ti150114	0.605	0.115	2.10E-07
X11	SALIDA JP/K	u150-ti150112	-0.011	0.123	0.930
X12	KERO/JP	u150-frCT15003	-0.004	0.001	0.001
X13	ACPM	u150-frCT15004	0.000	0.001	0.976
X14	VAP FDO T150	u150-fit15020	0.000	0.001	0.621
X19	REF MEDIO T 150	U150-FRCT15006	0.002	0.000	4.33E-09
X20	COMPOSICION CR	API	-0.257	0.206	0.213

Las variables seleccionadas para el desarrollo del modelo del *soft sensor* para predecir la T95% de recobrado del ACPM que cumplieron con el criterio de significación fueron: X3 (Temperatura Entrada Reflujo Inferior), X4 (Flujo de Reflujo Inferior), X5 (Temperatura Salida Reflujo Medio), X6 (Temperatura Entrada Reflujo Medio), X7 (Temperatura Cima T150), X8 (Presión Cima T150), X10 (Temperatura Salida ACPM), X12 (Flujo Producción Jet-A), X19 (Flujo Reflujo Medio) y X20 (Gravedad API Crudo Carga), esta última variable de entrada aunque no cumple con el criterio de la probabilidad de salida $0.213 > 0.05$, se incluyó dentro de las variables de entrada porque tiene un coeficiente significativamente diferente de cero y además por la experiencia y el objetivo de este trabajo la composición del crudo de carga es una variable fundamental para el desarrollo del modelo.

Una vez pre-procesados los datos recopilados y definidas las variables de entrada, a continuación se muestran las matrices de datos que se utilizaron finalmente para

la construcción de los modelos de los *soft sensor* para la predicción de los parámetros PFE del Jet A y T95 del ACPM a través del método ANN (*Artificial Neural Networks*) redes neuronales artificiales.

Tabla 17. Matriz datos para soft sensor PFE Jet A.

Muestra	Y1	X2		X5	X6		X8	X10	X11	X13	X14	X20
	PFE	SALIDA REF INF	SALIDA REF MED	REF.MED.T150	PRESION .CIMA T150		SALIDA ACPM	SALIDA JP/K	ACPM	VAP FDO T150	CRUDO	
		u150-ti150182	u150-ti150181	U150-TICT15003	u150-PIT15020	u150-ti150114						u150-ti150112
1	485.4	540.9	428.6	287.1	11.1	510.5	372.5	7266.5	1879.5	41.0		
2	471.7	559.4	416.4	294.0	9.4	501.1	370.0	5687.4	1708.0	41.4		
3	472.5	563.7	429.1	276.9	10.3	501.8	370.1	6576.0	1835.8	45.4		
4	497.8	553.5	438.1	281.1	11.7	508.0	381.2	7254.5	2390.8	42.8		
.		
.		
.		
626	408.6	554.2	383.4	306.4	11.2	469.8	354.4	5808.2	4885.8	33.7		

Tabla 18. Matriz datos para soft sensor T95 ACPM.

Muestra	Y2	X3	X4	X5	X6	X7	X8	X10	X12	X19	X20
	T95	REF.INF.T150	REF INF T150	SALIDA REF MED	REF.MED.T150	CIMA T150	PRESION .CIMA T150	SALIDA ACPM	KERO/JP	REF MEDIO T150	CRUDO
		U150-TICT15004	u150-frct15007	u150-ti150181	U150-TICT15003	U150-TICT15002	u150-PIT15020	u150-ti150114	u150-frct15003	U150-FRCT15006	API
1	634.3	383.6	6548.8	428.6	287.1	274.6	11.1	510.5	5097.5	11282.2	41.0
2	651	385.2	6463.9	437.1	276.3	279.1	10.3	508.8	5138.3	11212.4	47.3
3	629.1	389.9	6468.2	416.4	294.0	279.9	9.4	501.1	3881.9	11341.6	41.4
4	632.3	400.8	6453.0	429.1	276.9	275.1	10.3	501.8	5498.7	11350.6	45.4
.
.
.
594	608.4	398.2	5826.4	383.4	306.4	266.2	11.2	469.8	1879.4	13950.8	33.7

Finalmente la definición de los intervalos se fijó tomando como referencia las ventanas de operación, a partir de las cuales se tomaron los puntos críticos de control de la herramienta RIS (*Refinery Information System*) y los valores mínimos y máximos encontrados en los datos recopilados, los intervalos de las variables de entrada seleccionadas son los siguientes :

Tabla 19. Intervalos Variables de Entrada

Variables de Entrada		TAG	MAX	MIN
X2	SALIDA REF INF	u150-ti150182	650	510
X3	REF.INF.T150	U150-TICT15004	530	350
X4	REF INF T150	u150-fRCT15007	13000	4000
X5	SALIDA REF MED	u150-ti150181	530	360
X6	REF.MED.T150	U150-TICT15003	380	260
X7	CIMA T150	U150-TICT15002		260
X8	PRESION .CIMA T150	u150-PIT15020	14	
X10	SALIDA ACPM	u150-ti150114	560	450
X11	SALIDA JP/K	u150-ti150112	430	330
X13	ACPM	u150-fRCT15004	8800	3000
X12	KERO/JP	u150-fRCT15003	7800	1800
X19	REF MEDIO T 150	U150-FRCT15006	32000	8400
X20	COMPOSICION CR	API	48	22.0

6.3. CONSTRUCCIÓN, ENTRENAMIENTO Y VALIDACIÓN DE LAS REDES NEURONALES.

De acuerdo a como se mostró en la metodología (**tabla 9**) se construyeron con las herramientas NFTOOL y NNTOOL de Matlab ®, 26 redes neuronales para la predicción del punto final de ebullición (PFE) del producto Jet A y 26 redes neuronales para predecir el comportamiento de la T95%vol del producto ACPM.

De las 26 redes construidas para cada uno de los parámetros PFE del Jet A y T95 del ACPM, 12 fueron del tipo MLPFF (*Multilayer perceptron feed-forward backpropagation*), 10 tipo MLPCF (*Multilayer perceptron cascade-forward backpropagation*), 2 tipo RBN (*Radial basis*) y 2 tipo *perceptron*. Para el caso de las tipos multicapa MLPFF y MLPCF cada una de las redes construidas se evaluaron con dos funciones de entrenamiento la *Levenberg-Marquart backpropagation (trainlm)* y la *scaled conjugate gradient backpropagation (trainscg)*. Adicionalmente cada una de la redes construidas tipo multicapa tienen

diferentes combinaciones de las funciones de transferencia (tagsim, logsim y purelin) para la capas ocultas y de salida.

Los resultados de desempeño (coeficiente de correlación R y promedio del cuadrado de los errores MSE) de las redes neuronales multicapa construidas para la predicción de los parámetros PFE del Jet A y T95 del ACPM en las etapas de entrenamiento, validación y pruebas se muestran a continuación en la siguiente gráfica:

Tabla 20. Resultados Desempeño Redes Neuronales Tipo Multicapa para predecir PFE de Jet A y T95 del ACPM


#Red	Tipo de Red	Herramienta	# de Capas	# de Neuronas Capa Oculta	Variable de Salida	Funcion de Entrenamiento															
						TRAINLM								TRAINSCG							
						Entrenamiento		Validacion		Prueba1		Prueba2		Entrenamiento		Validacion		Prueba1		Prueba2	
R	MSE	R	MSE	R	MSE	R	MSE	R	MSE	R	MSE	R	MSE	R	MSE						
1	MLPFF	NFTOOL	2	10	PFE JET A	0,82	144,6	0,825	156,83	0,82	149,1	0,924	114,6	NA	NA	NA	NA	NA	NA	NA	NA
2	MLPFF	NFTOOL	2	10	T95 ACPM	0,86	104,8	0,87	95,03	0,86	88,9	0,93	64,44	NA	NA	NA	NA	NA	NA	NA	NA
3	MLPFF	NFTOOL	2	13	PFE JET A	0,852	129,7	0,84	143,62	0,82	170,3	0,93	95,29	NA	NA	NA	NA	NA	NA	NA	NA
4	MLPFF	NFTOOL	2	15	T95 ACPM	0,845	113	0,89	76,4	0,84	119,7	0,93	65,78	NA	NA	NA	NA	NA	NA	NA	NA
5	MLPFF	NFTOOL	2	10	PFE JET A	0,819	150	0,89	111,2	0,84	120	0,93	109,2	0,79	165	0,82	172,4	0,82	170	0,91	142
6	MLPFF	NFTOOL	2	10	T95 ACPM	0,84	112	0,9	76,5	0,86	99	0,93	63,8	0,81	140	0,89	100,2	0,83	120	0,926	70,3
7	MLPFF	NFTOOL	2	10	PFE JET A	0,84	128,6	0,84	128,6	0,84	180	0,94	96,8	0,79	155	0,84	121,2	0,83	140	0,92	126
8	MLPFF	NFTOOL	2	10	T95 ACPM	0,86	100	0,81	108,9	0,86	110	0,94	65,1	0,82	130	0,84	139,3	0,82	110	0,93	66,4
9	MLPFF	NFTOOL	2	10	PFE JET A	0,8	140	0,82	112,2	0,79	150	0,91	135	0,79	160	0,82	148,2	0,81	195	0,92	129,2
10	MLPFF	NFTOOL	2	10	T95 ACPM	0,8	142	0,84	106,6	0,85	140	0,93	66	0,81	132	0,83	130,3	0,83	123	0,93	67,1
11	MLPFF	NFTOOL	2	10	PFE JET A	0,83	135	0,85	120	0,81	131	0,93	109,7	0,81	156	0,84	158,7	0,8	160	0,92	125
12	MLPFF	NFTOOL	2	10	T95 ACPM	0,84	110	0,91	81,3	0,88	100	0,93	68,5	0,8	126	0,85	123,7	0,89	89	0,92	71,2
13	MLPFF	NFTOOL	2	10	PFE JET A	0,83	152	0,85	118,5	0,83	151	0,93	117,3	0,81	154	0,82	152,5	0,81	165	0,92	124
14	MLPFF	NFTOOL	2	10	T95 ACPM	0,82	120	0,86	113,4	0,89	72	0,92	73,7	0,8	150	0,86	89,8	0,86	105	0,92	74,1
15	MLPFF	NFTOOL	2	10	PFE JET A	0,79	180	0,8	151,8	0,84	130	0,91	132,5	0,79	165	0,81	159,6	0,79	180	0,91	145
16	MLPFF	NFTOOL	2	10	T95 ACPM	0,81	135	0,83	127,4	0,83	98	0,93	72,2	0,81	130	0,8	137,5	0,83	120	0,93	67,2
17	MLPFF	NFTOOL	2	10	PFE JET A	0,77	195	0,79	248,1	0,82	170	0,85	338,8	0,76	210	0,71	221,9	0,79	260	0,85	355
18	MLPFF	NFTOOL	2	10	T95 ACPM	0,84	110	0,78	184,3	0,89	98	0,9	115,3	0,79	155	0,84	122,5	0,81	150	0,87	140
19	MLPFF	NFTOOL	2	10	PFE JET A	0,77	200	0,73	192,4	0,81	180	0,85	331	0,75	212	0,72	202,8	0,81	175	0,86	358
20	MLPFF	NFTOOL	2	10	T95 ACPM	0,79	172	0,83	123,4	0,84	112	0,85	147,1	0,81	142	0,77	168,2	0,75	198	0,56	146
21	MLPFF	NFTOOL	2	10	PFE JET A	0,71	238	0,75	230,8	0,8	185	0,85	385,6	0,72	260	0,78	195,8	0,73	130	0,84	380
22	MLPFF	NFTOOL	2	10	T95 ACPM	0,77	180	0,82	132,9	0,8	132	0,84	154	0,75	160	0,81	147,8	0,83	147	0,85	154
23	MLPFF	NFTOOL	4	13	PFE JET A	0,83	145	0,82	169,1	0,87	105	0,92	124	0,79	185	0,83	117,6	0,82	185	0,91	133
24	MLPFF	NFTOOL	4	15	T95 ACPM	0,86	96	0,89	85,3	0,93	59	0,93	63	0,83	125	0,74	224,7	0,78	140	0,91	87,7
25	MLPCF	NFTOOL	2	10	PFE JET A	0,81	150	0,88	107,2	0,85	145	0,93	108,9	0,8	165	0,8	152,7	0,84	156	0,92	121
26	MLPCF	NFTOOL	2	10	T95 ACPM	0,87	95	0,86	90,6	0,9	95	0,94	54,41	0,81	135	0,86	97,7	0,83	110	0,93	65,8
27	MLPCF	NFTOOL	2	10	PFE JET A	0,82	150	0,86	132,1	0,8	148	0,93	99,7	0,8	160	0,8	232,2	0,8	120	0,92	129
28	MLPCF	NFTOOL	2	10	T95 ACPM	0,86	112	0,83	72,5	0,89	110	0,94	58	0,8	160	0,87	78,7	0,88	95	0,93	67,2
29	MLPCF	NFTOOL	2	10	PFE JET A	0,79	171	0,82	172,4	0,82	155	0,91	128,7	0,8	165	0,79	168,1	0,79	195	0,91	130
30	MLPCF	NFTOOL	2	10	T95 ACPM	0,81	150	0,83	100,9	0,83	145	0,92	74,8	0,82	130	0,81	135,4	0,82	120	0,93	63,6
31	MLPCF	NFTOOL	2	10	PFE JET A	0,83	165	0,9	88,48	0,82	160	0,94	96,1	0,79	180	0,81	137,4	0,84	142	0,91	134
32	MLPCF	NFTOOL	2	10	T95 ACPM	0,85	105	0,89	86,9	0,91	78	0,93	60	0,8	135	0,82	148,6	0,86	85	0,92	73,2
33	MLPCF	NFTOOL	2	10	PFE JET A	0,81	160	0,86	109,8	0,86	125	0,92	121	0,8	179	0,81	195	0,82	185	0,91	138
34	MLPCF	NFTOOL	2	10	T95 ACPM	0,84	110	0,85	97,7	0,9	86	0,93	58,8	0,79	195	0,86	97,7	0,81	60	0,91	83
35	MLPCF	NFTOOL	2	10	PFE JET A	0,79	165	0,8	161,6	0,83	180	0,91	133,4	0,8	180	0,8	137,1	0,82	175	0,91	135
36	MLPCF	NFTOOL	2	10	T95 ACPM	0,8	150	0,87	97,8	0,84	115	0,92	70,8	0,81	150	0,8	96,8	0,86	145	0,93	68
37	MLPCF	NFTOOL	2	10	PFE JET A	0,77	194	0,78	251	0,86	150	0,87	344,1	0,72	250	0,82	154,6	0,76	160	0,86	356
38	MLPCF	NFTOOL	2	10	T95 ACPM	0,81	150	0,87	128,7	0,8	110	0,87	133,3	0,77	180	0,84	122,3	0,8	115	0,87	141
39	MLPCF	NFTOOL	2	10	PFE JET A	0,77	210	0,77	165,2	0,79	280	0,86	352,1	0,79	210	0,76	247,5	0,79	180	0,86	355
40	MLPCF	NFTOOL	2	10	T95 ACPM	0,83	130	0,81	144,4	0,8	205	0,86	143	0,75	170	0,85	138,9	0,86	120	0,86	143
41	MLPCF	NFTOOL	2	10	PFE JET A	0,7	230	0,8	233,3	0,7	250	0,85	374,7	0,68	210	0,66	199,7	0,62	190	0,8	558
42	MLPCF	NFTOOL	2	10	T95 ACPM	0,78	168	0,78	178,3	0,8	140	0,86	150,6	0,76	165	0,81	142	0,79	180	0,85	152
43	MLPCF	NFTOOL	4	13	PFE JET A	0,84	138	0,86	139,4	0,89	98	0,92	119,9	0,81	164	0,84	163,2	0,86	98	0,92	126
44	MLPCF	NFTOOL	4	15	T95 ACPM	0,87	95	0,88	84,4	0,92	68	0,94	56,9	0,8	140	0,86	119,6	0,83	90	0,89	103

6.3.1. Resultados redes tipo multicapa para la predicción del PFE del Jet. De acuerdo con los resultados de desempeño, las redes multicapa con mejor desempeño (Coeficiente de correlación R y promedio de los errores al cuadrado MSE) para predecir el parámetro de PFE del Jet fueron la número 5, 7, 25, 27, 31 y 43; estas fueron entrenadas con la función *trainlm* cuya estructura se describe a continuación:

Red No 5:

- Tipo: *Multilayer perceptron feed-forward backpropagation*
- Número de Entradas: 9 (Corresponden a la variables de entrada previamente definidas,)
- Número de Capas Ocultas: 2
- Número de Neuronas por capa oculta:10
- Función de Transferencia en capas ocultas: Tansig.
- Función de Tranferencia en capa de salida: Purelin
- Función de Entrenamiento: Trainlm

Figura 61. Estructura Red Multicapa No 5




Red No 7:

- Tipo: *Multilayer perceptron feed-forward backpropagation*
- Número de Entradas: 9 (Corresponden a la variables de entrada previamente definidas)
- Número de Capas Ocultas: 2
- Número de Neuronas por capa oculta:10

- Función de Transferencia en capas ocultas: Logsig.
- Función de Transferencia en capa de salida: Purelin
- Función de Entrenamiento: Trainlm


Figura 62. Estructura Red Multicapa No 7



Red No 25:

- Tipo: *Multilayer perceptron Cascade-forward backpropagation*
- Número de Entradas: 9 (Corresponden a la variables de entrada previamente definidas,)
- Número de Capas Ocultas: 2
- Número de Neuronas por capa oculta:10
- Función de Transferencia en capas ocultas: Tansig.
- Función de Transferencia en capa de salida: Purelin.
- Función de Entrenamiento: Trainlm

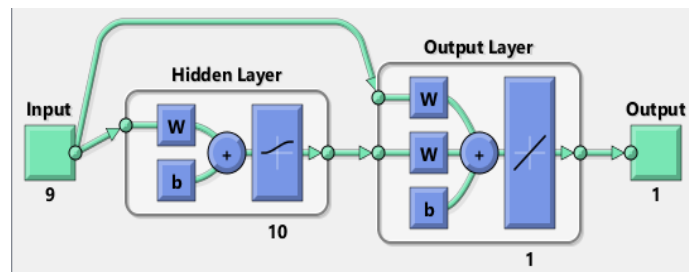
Figura 63. Estructura Red Multicapa No 25



Red No 27:

- Tipo: *Multilayer perceptron cascade-forward backpropagation*
- Número de Entradas: 9 (Corresponden a la variables de entrada previamente definidas,)
- Número de Capas Ocultas: 2
- Número de Neuronas por capa oculta:10
- Función de Transferencia en capas ocultas: Logsig.
- Función de Transferencia en capa de salida: Purelin
- Función de Entrenamiento: Trainlm

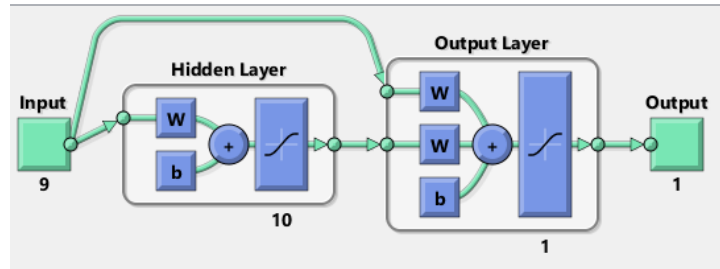
Figura 64. Estructura Red Multicapa No 27



Red No 31:

- Tipo: *Multilayer perceptron cascade-forward backpropagation*
- Número de Entradas: 9 (Corresponden a la variables de entrada previamente definidas,)
- Número de Capas Ocultas: 2
- Número de Neuronas por capa oculta:10
- Función de Transferencia en capas ocultas: Tansig.
- Función de Transferencia en capa de salida: Tansig.
- Función de Entrenamiento: Trainlm.


Figura 65. Estructura Red Multicapa No 31



Red No 43:

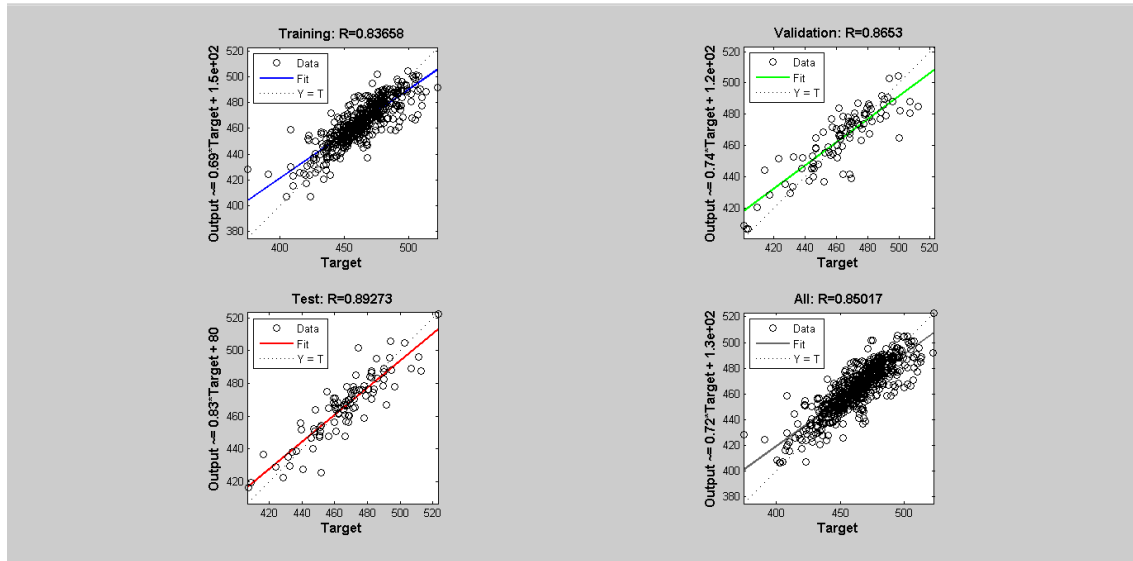
- Tipo: *Multilayer perceptron cascade-forward backpropagation*
- Número de Entradas: 9 (Corresponden a la variables de entrada previamente definidas,)
- Número de Capas Ocultas: 4
- Número de Neuronas por capa oculta:13
- Función de Transferencia en capas ocultas: Tansig.
- Función de Transferencia en capa de salida: Purelin.
- Función de Entrenamiento: Trainlm

Figura 66. Estructura Red Multicapa No 43




A continuación se muestra el detalle de los resultados de desempeño de la red tipo multicapa número 43 para predecir el PFE del Jet-A la cual presenta los mejores valores del coeficiente de correlación R y promedio de los errores al cuadrado MSE en las etapas de entrenamiento, validación y pruebas.

Figura 67. Resultados Coeficientes de Correlación R para las etapas de entrenamiento, validación y prueba de la red multicapa No 43 para predecir el PFE del Jet A



Como se puede observar los resultados del coeficiente R están por encima de 0.8 con valores de 0.836, 0.865 y 0.893 para las etapas de entrenamiento, validación y prueba, respectivamente.

Figura 68. Resultados del promedio de los errores al cuadrado MSE de las etapas de entrenamiento, validación y prueba de la red multicapa No 43 para predecir el PFE del Jet A



En la figura anterior se muestra los valores de MSE para las etapas de entrenamiento, validación y prueba cuyos valores son 138, 139.4 y 98 respectivamente.

Como se indicó en el capítulo de metodología para las redes neuronales multicapa, se realizó una prueba adicional (prueba 2) utilizando los datos recopilados recientemente (Mayo a Octubre de 2015) de las variables de entrada y salida (*inputs-targets*), los resultados obtenidos para los parámetros R y MSE para la red neuronal multicapa número 43 para la predicción del PFE del Jet A fueron 0.92 (Figura 69) y 119.9 (Figura 70):

Figura 69. Coeficiente de Correlación R Prueba 2 Red Multicapa No 43 para predicción PFE de Jet A





Figura 70. Promedio de los errores al cuadrado MSE Prueba 2 Red Multicapa No 43 para predicción PFE de Jet A



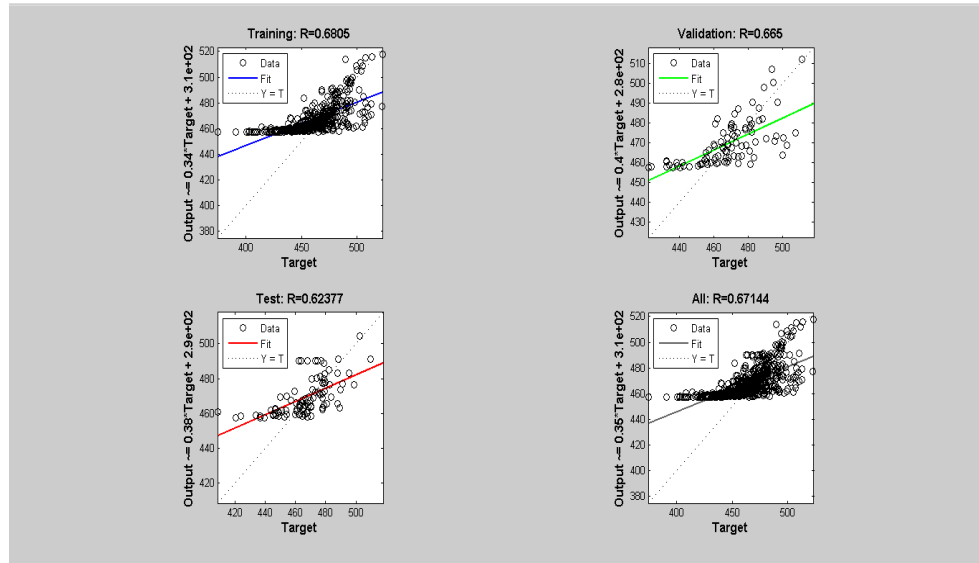
De las redes neuronales multicapa construidas para predecir el PFE del Jet A la que presentó el peor desempeño fue la número 41 entrenada con la función *trainscg* que tiene las siguientes características en su estructura:

Red No 41:

- Tipo: *Multilayer perceptron cascade-forward backpropagation*
- Número de Entradas: 9 (Corresponden a la variables de entrada previamente definidas,)
- Número de Capas Ocultas: 2
- Número de Neuronas por capa oculta:10
- Función de Transferencia en capas ocultas: Purelin
- Función de Transferencia en capa de salida: Logsig
- Función de Entrenamiento: Trainscg

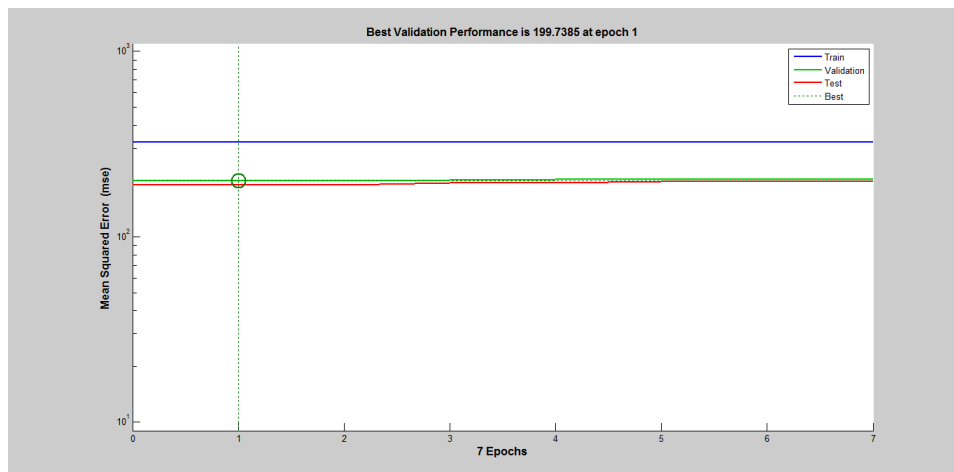
Los resultados de desempeño R y MSE de la red neuronal No 41 se muestran a continuación:

Figura 71. Resultados Coeficientes de Correlación R para las etapas de entrenamiento, validación y prueba de la red multicapa No 41 para predecir el PFE del Jet A



Los resultados para el coeficiente de correlación R están por debajo de 0.7 con valores de 0.68, 0.66 y 0.62 para las etapas de entrenamiento, validación y prueba.

Figura 72. Resultados del promedio de los errores al cuadrado MSE de las etapas de entrenamiento, validación y prueba de la red multicapa No 41 para predecir el PFE del Jet A



Los valores de MSE para la red neuronal multicapa No 41 para las etapas de entrenamiento, validación y prueba fueron 210, 199.7 y 190 respectivamente; siendo los valores más altos para todas las redes multicapa construidas.

Los resultados de R (Figura 73) y MSE (Figura 74) para la prueba adicional, realizada con los datos recopilados recientemente para la red neuronal multicapa No 41 se muestran a continuación:

Figura 73. Coeficiente de Correlación R Prueba 2 Red Multicapa No 41 para predicción PFE de Jet A





Figura 74. Promedio de los errores al cuadrado MSE Prueba 2 Red Multicapa No 41 para predicción PFE de Jet A



Como se observa los valores R y MSE para la red multicapa No 41, para predecir el PFE del Jet A fueron de 0.80 y 557.8 respectivamente; mostrando el desempeño más bajo de todas las redes neuronales multicapa construidas.

Tomando como referencia el trabajo publicado por Mohler *et al.* (año) donde utilizaron redes neuronales tipo multicapa con resultados en el coeficiente de correlación (R) de 0.81 y 0.83 en las etapas de entrenamiento y prueba respectivamente; se puede inferir que los resultados obtenidos con la red tipo multicapa No 43 muestran un alto desempeño de predicción para el PFE del Jet. En efecto, los valores del coeficiente de correlación (R) en las etapas de entrenamiento, validación y pruebas (0.84, 0.86, 0.89 y 0.92) fueron mayores o más cercanos a 1.0 que los obtenidos en el trabajo referido. Así mismo, se debe considerar que valores de R iguales a 1.0 indican que el modelo es perfecto, lo cual es estadísticamente improbable si se considera el alto grado de no linealidad de este tipo de procesos.

6.3.2. Resultados redes tipo multicapa para la predicción de la T95 del ACPM.

Para predecir la T95 de ACPM las redes neuronales multicapa que presentaron mejor desempeño de acuerdo con los resultados mostrados en la tabla 14 fueron las redes No 24, 44, 32, 26, 12 y 6; siendo todas estas entrenadas con la función *trainlm*. Al igual que las redes multicapa construidas para predecir el PFE del Jet A, la función de entrenamiento que presenta mejor desempeño para esta aplicación es la *trainlm* vs la *trainscg*, lo cual está acorde a lo esperado pues de acuerdo a estudios realizados, la función *trainlm* (*Levenberg-Marquardt*) presenta mejor desempeño para problemas de funciones de aproximación (regresión no lineal) respecto a la función *trainscg* (*scaled conjugate gradient*) la cual no es especializada en este tipo de problemas pero presenta buen desempeño para una


amplia variedad de otros tipos de aplicaciones como por ejemplo el reconocimiento de patrones¹³².

A continuación se muestra la descripción de la estructura de las redes neuronales multicapa con mejor desempeño para predecir la T95 del ACPM:

Red No 24:

- Tipo: *Multilayer perceptron feed-forward backpropagation*
- Número de Entradas: 10 (Corresponden a la variables de entrada previamente definidas)
- Número de Capas Ocultas: 4
- Número de Neuronas por capa oculta:15
- Función de Transferencia en capas ocultas: Tansig.
- Función de Transferencia en capa de salida: Purelin.
- Función de Entrenamiento: Trainlm

Figura 75. Estructura Red Multicapa No 44




Red No 44:

- Tipo: *Multilayer perceptron cascade-forward backpropagation*
- Número de Entradas: 10 (Corresponden a la variables de entrada previamente definidas)
- Número de Capas Ocultas: 4
- Número de Neuronas por capa oculta:15

¹³² H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB © User Guide, The Math Works, Cap 2,3 y 7, 2012.

- Función de Transferencia en capas ocultas: Tansig.
- Función de Transferencia en capa de salida: Purelin.
- Función de Entrenamiento: Trainlm.

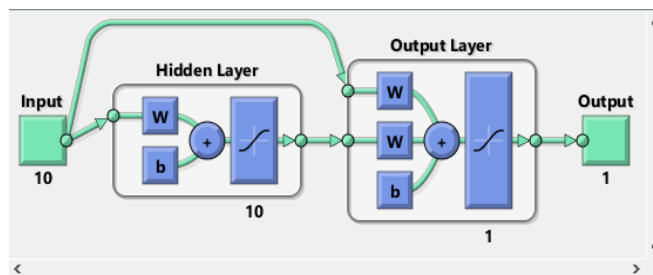
Figura 76. Estructura Red Multicapa No 44



Red No 32:

- Tipo: *Multilayer perceptron cascade-forward backpropagation*
- Número de Entradas: 10 (Corresponden a la variables de entrada previamente definidas)
- Número de Capas Ocultas: 2
- Número de Neuronas por capa oculta:10
- Función de Transferencia en capas ocultas: Tansig.
- Función de Transferencia en capa de salida: Tansig.
- Función de Entrenamiento: Trainlm


Figura 77. Estructura Red Multicapa No 32



Red No 26:

- Tipo: *Multilayer perceptron cascade-forward backpropagation*
- Número de Entradas: 10 (Corresponden a la variables de entrada previamente definidas)
- Número de Capas Ocultas: 2
- Número de Neuronas por capa oculta:10
- Función de Transferencia en capas ocultas: Tansig.
- Función de Transferencia en capa de salida: Purelin.
- Función de Entrenamiento: Trainlm.


Figura 78. Estructura Red Multicapa No 26



Red No 12:

- Tipo: *Multilayer perceptron feed-forward backpropagation*
- Número de Entradas: 10 (Corresponden a la variables de entrada previamente definidas)
- Número de Capas Ocultas: 2
- Número de Neuronas por capa oculta:10
- Función de Transferencia en capas ocultas: Tansig.
- Función de Transferencia en capa de salida: Tansig.
- Función de Entrenamiento: Trainlm


Figura 79. Estructura Red Multicapa No 12



Red No 6:

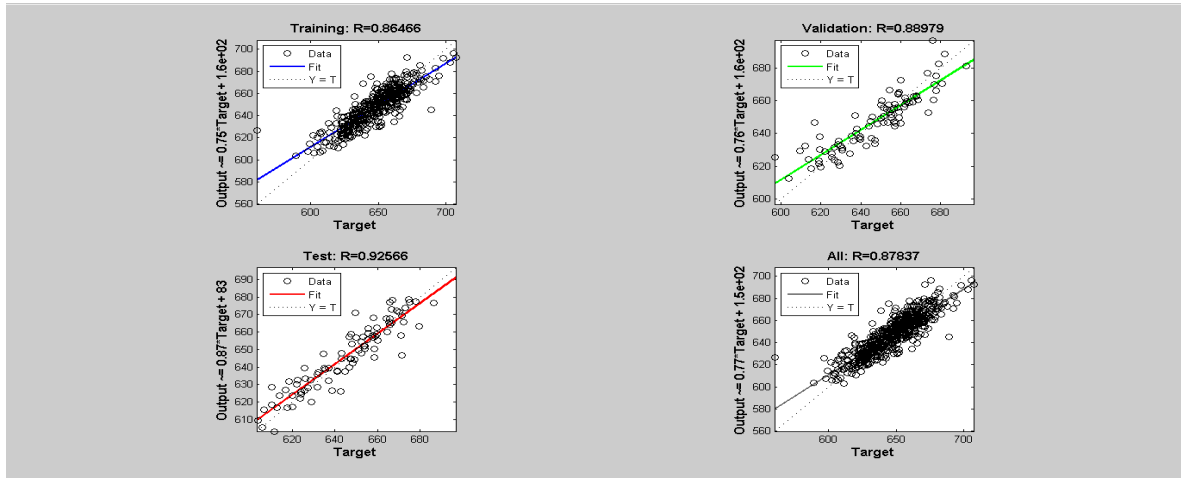
- Tipo: *Multilayer perceptron feed-forward backpropagation*
- Número de Entradas: 10 (Corresponden a la variables de entrada previamente definidas)
- Número de Capas Ocultas: 2
- Número de Neuronas por capa oculta:10
- Función de Transferencia en capas ocultas: Tansig.
- Función de Transferencia en capa de salida: Purelin.
- Función de Entrenamiento: Trainlm.

Figura 80. Estructura Red Multicapa No 6




La red neuronal tipo multicapa que presentó los mejores valores de R y MSE en las etapas de entrenamiento, validación y pruebas fue la No 24, el detalle de los resultados se muestran a continuación:

Figura 81. Resultados Coeficientes de Correlación R para las etapas de entrenamiento, validación y prueba de la red multicapa No 24 para predecir la T95 del ACPM.



Como se observa en la figura 21 los resultados del coeficiente de correlación están por encima de 0.8 con valores de 0.86, 0.89 y 0.92 para las etapas de entrenamiento, validación y prueba, siendo éstos los valores más altos obtenidos.

Figura 82. Resultados del promedio de los errores al cuadrado MSE de las etapas de entrenamiento, validación y prueba de la red multicapa No 24 para predecir la T95 del ACPM



Respecto a los valores de MSE fueron de 96, 85.3 y 59 para las etapas de entrenamiento, validación y prueba; los cuales son los valores más bajos obtenidos respecto a las demás redes construidas.

Los valores de R (Figura 83) y MSE (Figura 84) para la red neuronal No 24 obtenidos en la prueba adicional realizada con los datos de planta y laboratorio recientemente recopilados (*inputs-targets*) se muestran a continuación:

Figura 83. Coeficiente de Correlación R Prueba 2 Red Multicapa No 24 para predicción T95 del ACPM





Figura 84. Promedio de los errores al cuadrado MSE Prueba 2 Red Multicapa No 24 para predicción de la T95 del ACPM




Los valores para la prueba adicional de la red No 24 fueron de 0.93 y 62.98 para los parámetros R y MSE respectivamente.

Para la predicción de la T95 del ACPM, la red neuronal tipo multicapa que presentó el más bajo desempeño según la tabla 14 fue la número 20 cuya estructura se resumen a continuación:

Red No 20:

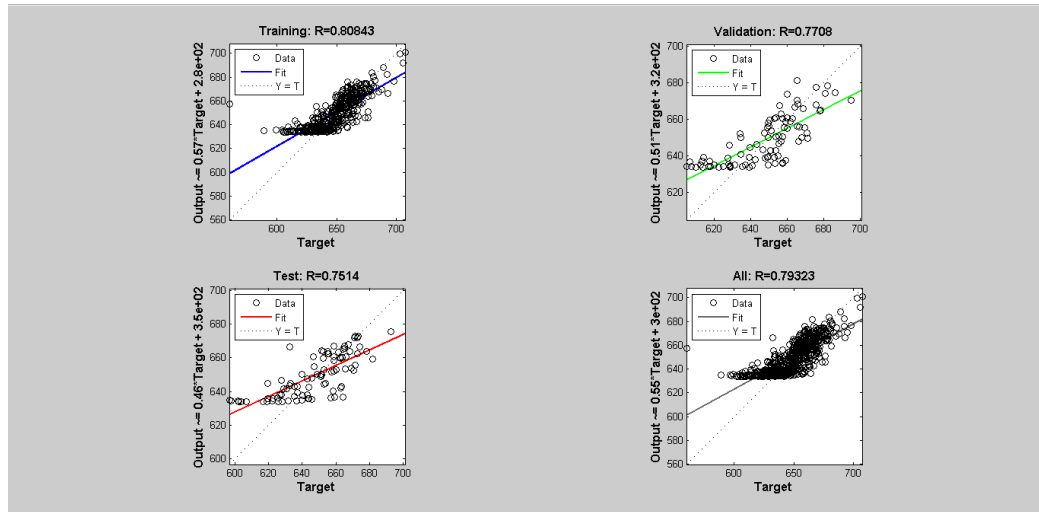
- Tipo: *Multilayer perceptron feed-forward backpropagation*
- Número de Entradas: 10 (Corresponden a la variables de entrada previamente definidas)
- Número de Capas Ocultas: 2
- Número de Neuronas por capa oculta:10
- Función de Transferencia en capas ocultas: Logsig.
- Función de Transferencia en capa de salida: Logsig.
- Función de Entrenamiento: Trainscg.

Figura 85. Estructura Red Multicapa No 20



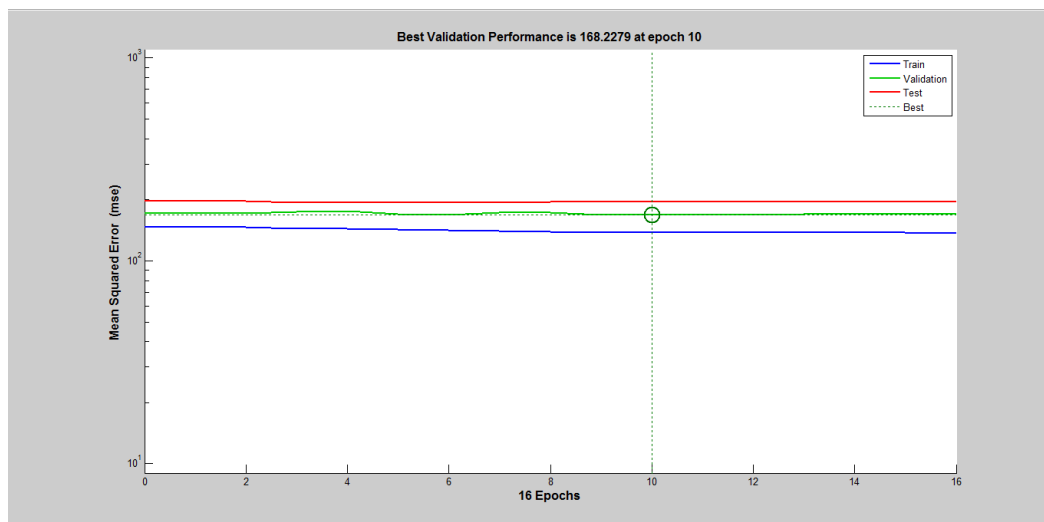
El detalle de los resultados de R y MSE para la red neuronal No 20 se muestran a continuación:

Figura 86. Resultados Coeficientes de Correlación R para las etapas de entrenamiento, validación y prueba de la red multicapa No 20 para predecir la T95 del ACPM.



Los valores de R para la etapa de entrenamiento, validación y prueba fueron de 0.8, 0.77 y 0.75, respectivamente; siendo éstos los más bajos valores obtenidos de las redes multicapa construidas.

Figura 87. Resultados del promedio de los errores al cuadrado MSE de las etapas de entrenamiento, validación y prueba de la red multicapa No 20 para predecir la T95 del ACPM



Respecto a los valores promedio de los errores al cuadrado MSE, éstos fueron respectivamente de 142, 168.2 y 146, para las etapas de entrenamiento, validación y prueba.

Los resultados de R y MSE de la red multicapa No 20 para la prueba adicional con los datos de entrada y salida más recientes para predecir la T95 del ACPM se muestran a continuación:

Figura 88. Coeficiente de Correlación R Prueba 2 Red Multicapa No 20 para predicción T95 del ACPM





Figura 89. Promedio de los errores al cuadrado MSE Prueba 2 Red Multicapa No 20 para predicción de la T95 del ACPM



En resumen los resultados obtenidos en las redes multicapa para la predicción de la T95 del ACPM específicamente en la red No 24 presentan un alto desempeño al igual que los obtenidos en la predicción del PFE del Jet, con valores en el coeficiente de correlación (R) mayores o más cercanos a 1.0 (0.86, 0.89 ,0.92 y 0.93) en las etapas de entrenamiento, validación y pruebas que los obtenidos en trabajos preliminares como el referenciado en la sección anterior (Mohler *et al.*, año) G).

6.3.3. Resultados redes tipo perceptron y base radial para la predicción del PFE del Jet y T95 del ACPM. Los resultados de las redes neuronales construidas tipo *perceptron* y *radial basis* para predecir el PFE del Jet A y la T95 del ACPM se muestran a continuación:

Tabla 21. Resultados Desempeño Redes Neuronales Tipo Perceptron y Radial Basis para predecir PFE de Jet A y T95 del ACPM


#Red	Tipo de Red	Herramienta	# de Capas	# de Neuronas Capa Oculta	Variable de Salida	Prueba1	
						R	MSE
45	P	NNTOOL	NA	NA	PFE JET A	NA	203308
46	P	NNTOOL	NA	NA	T95 ACPM	NA	412237
47	P	NNTOOL	NA	NA	PFE JET A	NA	203208
48	P	NNTOOL	NA	NA	T95 ACPM	NA	412237
49	RB(<i>exact fit</i>)	NNTOOL	NA	626	PFE JET A	1	0
50	RB(<i>exact fit</i>)	NNTOOL	NA	594	T95 ACPM	1	0
51	RB (<i>fewer neuron s</i>)	NNTOOL	NA	582	PFE JET A	0,99	9,8
52	RB (<i>fewer neuron s</i>)	NNTOOL	NA	536	T95 ACPM	0,99	9.92

Como se puede apreciar, los resultados la redes neuronales tipo *perceptron* de una sola capa no presentan un buen desempeño para predecir el PFE del Jet A y T95 del ACPM; obteniéndose como valores de salida una matriz de unos, de acuerdo con la revisión bibliográfica este tipo de redes tienen buen desempeño para reconocimiento de patrones y no para para funciones de aproximación. A manera de ejemplo se mostrará el detalle de los resultados de la red neuronal tipo *perceptron* No 45:

Red No 45:

- Tipo: *Perceptron*
- Número de Entradas: 9 (Corresponden a la variables de entrada previamente definidas)
- Número de Capas Ocultas: 1
- Número de Neuronas por capa oculta:1
- Función de Transferencia: Hardlim
- Función de Entrenamiento: Trainc (*Cyclical Weight*).

Figura 90. Estructura Red Multicapa No 45



Los resultados de R y MSE de la red No 45 tipo *perceptron* fueron los siguientes:

Figura 91. Coeficiente de Correlación R etapa de prueba Red *Perceptron* No 45 para predicción del PFE del Jet A.




Figura 92. Promedio de los errores al cuadrado MSE Prueba Red *Perceptron* No 45 para predicción del PFE del Jet A.





Figura 93. Resultados del promedio del error absoluto de las etapa de entrenamiento de la red *perceptron* No 45 para predecir el PFE del Jet A.



También es importante decir que el tiempo de cálculo para las redes tipo *perceptron* fue de 45 minutos vs 0.3 minutos (18 segundos) necesarios para las redes tipo multicapa, utilizando un procesador Intel ® Core ™ i7 3537U CPU @ 2.00 GHz – 2.00GHz


6.3.3.1. Resultado redes tipo base radial para la predicción del PFE del Jet y T95 del ACPM: Respecto al desempeño de las redes neuronales tipo *radial basis* como se aprecia en la tabla No 15, es el mejor de todas las redes construidas para predecir el PFE del Jet A y T95 del ACPM con valores de R y MSE de 1 y 0 respectivamente para las tipo *exact fit* y 0.99 y 9.92 para las tipo *fewer neurons*. Sin embargo, el número de neuronas necesarias en la capa oculta para lograr este desempeño es elevado con valores para la tipo *exact fit* de 626 y 594 neuronas para predecir el PFE del Jet A y T95 del ACPM, respectivamente. En lo que concierne a la tipo *fewer neurons* se necesitaron 582 neuronas para predecir el PFE del Jet A y 536 neuronas para predecir la T95 del ACPM. Este mayor número de neuronas incrementa el tiempo de cálculo a valores de 3 a 5 minutos para la redes tipo *radial basis* vs 18 segundos necesarios para la tipo multicapa utilizando un procesador Intel® Core™ i7 3537U CPU @ 2.00 GHz – 2.00GHz; lo cual es considerado como una desventaja para las redes tipo *radial basis* al momento de ser utilizadas como modelo en un *soft sensor* para predecir en línea el PFE del Jet A y T95 del ACPM.

A manera de ejemplo se mostrará el detalle de la estructura y resultados de desempeño de las redes neuronales tipo *radial basis* No 51 y 52.

Red No 51:

- Tipo : *Radial Basis*
- Número de Entradas: 9 (Corresponden a la variables de entrada previamente definidas)
- Número de Capas Ocultas: 1
- Número de Neuronas por capa oculta: 582
- Función de Transferencia Capa Oculta: Redbas
- Función de Transferencia Capara de Salida: Purelin
- Función de Entrenamiento: Newreb

Figura 94. Estructura Red Radial Basis No 51



Los resultados de desempeño de la red neuronal No 51 *radial basis* para predecir el PFE del Jet A son los siguientes:

Figura 95. Coeficiente de Correlación R etapa de prueba Red Radial Basis No 51 para predicción del PFE del Jet A.





Figura 96. Resultado del promedio del error al cuadrado MSE de la etapa de prueba de la red *perceptron* No 51 para predecir el PFE del Jet A.




Los valores de R y MSE para la red tipo *radial basis* No 51 fueron de 0.989 y 9.80 como se observa en las figuras 95 y 96.

Red No 52:


- Tipo : *Radial Basis*
- Número de Entradas: 10 (Corresponden a la variables de entrada previamente definidas)
- Número de Capas Ocultas: 1
- Número de Neuronas por capa : 536
- Función de Transferencia Capa Oculta: Redbas
- Función de Transferencia Capara de Salida: Purelin
- Función de Entrenamiento: Newreb

Figura 97. Estructura Red Radial Basis No 51




Los resultados de red No 52 tipo *radial basis* para predecir la T95 del ACPM se muestran a continuación:

Figura 98. Coeficiente de Correlación R etapa de prueba Red *Radial Basis* No 52 para predicción de la T95 del ACPM.



Los valores de R y MSE para la red tipo *radial basis* No 52 fueron de 0.987 y 9.92 como se muestra en las figuras 98 y 99.

Figura 99. Resultado del promedio del error al cuadrado MSE de la etapa de prueba de la red *perceptron* No 52 para predecir la T95 del ACPM.



De acuerdo con las Figuras 98 y 99, los valores de los parámetros de desempeño para la red No 52 tipo *radial basis* para predecir la T95 del ACPM fueron de 0.987 y 9.92 para el coeficiente de correlación R y promedio de los errores al cuadrado MSE, respectivamente.

6.4. ESTIMACIÓN DE BENEFICIOS POR IMPLEMENTACIÓN DEL SOFT SENSOR PARA PREDECIR EL PFE DEL JET Y T95 DEL ACPM EN U150.

Teniendo en cuenta los resultados de alto desempeño de predicción para el PFE del Jet y T95 del ACPM de la U150 de las redes neuronales construidas, se evaluó el efecto que se tendría al implementar estos modelos para la predicción en línea de estos parámetros en el control avanzado de proceso de la U150. El análisis partió del hecho que actualmente se tiene tan sólo un dato diario de laboratorio para estos parámetros, los cuales se alimentan al control avanzado (para el caso del ACPM actualmente se alimenta el PFE y no la T95) el cual a partir de esta información y las condiciones de operación infiere valores futuros a través de un modelo lineal el cual no tiene en cuenta la composición del crudo cargado obteniendo predicciones con un alto margen de error, dada la alta variabilidad en la carga.

El principal beneficio para la U150 de implementar un sistema de medición en línea, para los parámetros del PFE del Jet y T95 del ACPM que alimente el control avanzado de proceso a través de un *soft sensor* basado en un modelo no lineal utilizando redes neuronales que a su vez se alimenten de las variables de operación y composición de la carga, es el de maximizar la producción de estas corrientes manteniendo sus parámetros de calidad en control.

Las especificaciones esperadas para el PFE del Jet y T95 del ACPM en la T150 de acuerdo a su diseño son de 480°F Max y 680°F Max, respectivamente, valores

a los cuales las torres de fraccionadoras como la T150 a través del control avanzado deberían estar direccionadas siempre a conseguir para mantener al máximo posible la producción de estas corrientes y no perder calidad. Teniendo en cuenta ésto la T150 como se evidencia en la tendencia del PFE del Jet y T95 del ACPM para el periodo observado, muestra valores alejados de estas especificaciones un 78% y 98% del tiempo con promedios de 465°F y 647°F respectivamente.

Figura 100. PFE del Jet T150 respecto a valor máximo esperado.





Figura 101. T95 del ACPM T150 respecto a valor máximo esperado.



De acuerdo con la matriz de control avanzado de proceso de la U150 un aumento de 100 BPD en las producciones de Jet y ACPM equivalen a un aumento de 1.1°F en el PFE del Jet y 4.5 °F en el PFE del ACPM que son equivalentes a la T95 del ACPM, por tanto de acuerdo con la diferencia actual entre los valores reales y esperados de 15°F y 33°F respectivamente; se estima una recuperación potencial de destilados medios (Jet + ACPM) de 1 800 BPD que equivalen un 5%vol más de rendimientos de medios frente 24%vol rendimiento actual con un beneficio estimado de 17MUS\$/año. El detalle del cálculo se muestra a continuación:

BPD JET Recuperados

$$= \left(\frac{100\text{BPD}}{1.1^\circ\text{F}(\text{Aumento PFE})} * 15^\circ\text{F}(\text{Esperado} - \text{Real}) \right)$$

* 0.78 (%tiempo)

$$\text{BPD JET Recuperados} = 1063 \text{ BPD}$$

BPD ACPM Recuperados

$$= \left(\frac{100BPD}{4.5^{\circ}F(Aumento\ PFE)} * 33^{\circ}F(Esperado - Real) \right) \\ * 0.98 (\%tiempo)$$

$$BPD\ ACPM\ Recuperados = 719\ BPD$$

$$BPD\ Destilados\ Medios\ Recuperados = 1063BPD + 719\ BPD \approx 1800\ BPD$$

$$Beneficio\ Estimado = 1800\ BPD * 15 \frac{US\$}{BlS} * 365 \frac{dias}{año} \approx \frac{9.85MUS\$}{Año}$$

La implementación de estos modelos como recomendación de este trabajo de aplicación se deberá realizar mediante la importación de los códigos de programación de las redes neuronales que mostraron el mejor desempeño (las tipo multicapa No 43 y 20, y las tipo *radial basis* No 49 y 50) desde Matlab ® al modelo general del control avanzado de proceso (CAP) de la U150 para posterior evaluación de la predicción en línea y cuantificación de beneficios económicos reales.

7. CONCLUSIONES

Como conclusiones del presente trabajo de aplicación “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” se tiene las siguientes:

Se propone un modelo *soft sensor* (analizador virtual) para predecir el PFE del Jet A y T95 ACPM de la U150 respectivamente. Para el PFE Jet se plantea la RNA Multicapa No. 43 (R: 0.877 y MSE : 23.82) y para el T95 del ACPM la red multicapa No 24 (R: 0.90 y MSE : 75.82). En todos los modelos se emplean las condiciones de operación de la torre de destilación atmosférica T150 (presiones, temperatura y flujos) y calidad de la carga de crudo (gravedad API).

De acuerdo con los criterios utilizados: matriz dinámica del control avanzado, diagrama de relación de parámetros en destilación, experiencia operativa y regresión lineal múltiple, se definieron 9 variables de entrada para la construcción del modelo soft sensor para predecir el PFE del Jet A y 10 variables de entrada para la construcción del modelo soft sensor para predecir la T95 del ACPM, entre las variables definidas se encuentran flujos, temperaturas y presiones de la torre destilación T150 y la gravedad API del crudo carga.

De los tipos de redes neuronales construidas para predecir el PFE del Jet A y T95 del ACPM de la U150 las que presentan mejor desempeño son las tipo MLP (*Multilayer Perceptron*) y RBN (*Radial Basis Network*) coincidiendo con lo encontrado en el estado del arte de trabajos similares. Sin embargo, se descartan

las tipo base radial debido a que implican un gran número de neuronas en la capa oculta que incrementan significativamente el tiempo de cálculo requerido del modelo.

Con la implementación del *soft sensor* para la predicción del PFE del Jet y T95 del ACPM se estiman beneficios económicos ocasionados por la maximización de Jet y ACPM en la U150 de 9.85 MUS\$/año por aumento de un 4.7% en el rendimiento actual de destilados medios en la T150 que equivalen a 1 800 Bls/día para la capacidad de carga de diseño de la unidad 38 Kbls/día.

8. RECOMENDACIONES

Incluir en el modelo de control avanzado de proceso (CAP) de la U150 las redes neuronales construidas en el presente trabajo de aplicación que presentaron el mejor desempeño, las tipo multicapa No 43 y 24.

Introducir en la pantalla del sistema de control distribuido con siglas en inglés (DCS) de la U150 las señales de salida del *soft sensor* del PFE de Jet y T95 del ACPM para monitoreo y revisión de tendencias.

Una vez incluidos los modelos en el CAP evaluar los beneficios económicos ocasionados por la maximización de Jet A y ACPM en la U150 que se estiman sean de 9.85 MUS\$/año por aumento de un 4.7% en el rendimiento actual de destilados medios en la T150 que equivalen a 1 800 Bls/día para la capacidad de carga de diseño de la unidad 38 Kbls/día.

Implementar un densitómetro para medición en línea de la gravedad API del crudo cargado a la entrada de la U150 con el objetivo de mejorar aún más el desempeño de las redes neuronales construidas para predecir el PFE del Jet A y T95 del ACPM, teniendo en cuenta que como limitación actual el dato de gravedad API del crudo de carga actualmente se obtiene por un análisis de laboratorio a una muestra diaria del tanque de carga.

BIBLIOGRAFIAS

A. CASALI, G. GONZALEZ, F. TORRES, G. VALLEBUONA, L. CASTELLI, and P. GIMENEZ, Particle size distribution soft-sensor for a grinding circuit, Powder technology, Vol 99, págs 15-21, 1998.

A. PARDO, Análisis de Datos y Multivariable, Dpto de Materiales Universidad Complutense, Cap 18, 2000.

A. ROGINA, L. SSKO, I. MOLHER, Z. UJEVIC and N. BOLF, Soft sensors for continuous product quality estimation (in crude distillation unit), Chemical engineering research and design, Vol 89, págs 2070-2077, 2011.

D. DONG, T. MCAVOY, and L. CHANG, Emission monitoring using multivariate soft sensors, Proceedings of the American Control Conference, Vol 1, págs.761-765, 1995.

D. SLISKOVIC, R. GRBIC, and Z. HOCENSKI, Methods for Plant Data-Based Process Modeling in Soft- Sensor Development, Automatica 52, Vol 4, págs 306-318, 2011.

ECOPETROL S.A. Coordinación Ingeniería de Proceso GTE, Gerencia Refinería de Barrancabermeja, Diagrama de Banderas U150, 2002.

ECOPETROL, W:\Planeación de la producción \Planeación y Programación de la Producción\Análisis Económicos\Potenciales, 2014.

GRB-ECOPETROL S.A., Manual de descripción de procesos de la unidad de crudo U150 MDPU, RWD, Cap 3 - 6, 2008.

H. DEMUTH and M. BEALE, Neural Network Toolbox For Use With MATLAB ® User Guide, The Math Works, Cap 2,3 y 7, 2012.

I. MOHLER, G. GALINEC, N. HOLBLING, N. BOLF and Z. UJEVIC, Soft sensors for diesel fuel property estimation, Chemical Engineering Transactions, Vol 21, 2010.

INGENIEROS CONTROL AVANZADO, Gerencia Refinería de Barrancabermeja, Matriz Dinamica Control Avanzado de Proceso U150, Ecopetrol S.A., 2009.

J. HILERA y V. MARTINEZ, Redes Neuronales Artificiales Fundamentos, Modelos y Aplicaciones, Addison-Wesley Iberoamerica, Cap 3, 1995

J. MACIAS, P. ANGELOV, and Y. ZHOU, Soft sensors for predicting crude oil distillation side streams using evolving Takagi-Sugeno fuzzy models. Result outlined, Proceedings of 2nd Intern. Symposium on evolving fuzzy systems, págs 214-220, 2006.

L. FORTUNA, S. GRAZIANI, A. RIZZO, and M. XIBILIA, Soft sensors for monitoring and control of industrial processes, Springer Verlag, 2007.

L. FORTUNA, S. GRAZIANI, and M. XIBILIA, Soft sensors for product quality monitoring in debutanizer distillation columns, Control Engineering Practice, Vol 13, págs 499-508, 2005.

L. TAOFEEK, G. BABAGANA and A. AKPOVETA, A Review of an Expert System Design for Crude Oil Distillation Column Using The Neural Networks Model and

Process Optimization and Control Using Genetic Algorithm Framework, Advances in Chemical Engineering and Science, págs 164-167, 2013.

M. AL SHAMISI, A. ASSI and H. HEJASE, USING MATLAB® to Develop Artificial Neural Network Models for Predicting Global Solar Radiation in Al Ain City-UAE, InTech, 2011.

N. BOLF, M. IVANDIC, and G. GALINEC, Soft sensors for crude distillation unit product properties and estimation and control, Control and automation, Vol 16, págs 1804-1809, 2008.

R. LUO, H. SHAO, and Z. ZHANG, Fuzzy-neural-netbased inferential control for a high-purity distillation column, Control Engineering Practice, Vol 3, págs 31-40, 1995.

R. PERRY, Manual del Ingeniero Químico, Destilación, Vol 2, Cap 13, 1997.

S. BHAT, T. CHATTERJEE, and N. SARAF , On-Line data processing and product properties prediction for crude distillation units, Journal of process control Vol 14, págs 61-77, 2004.

UOP Inc, Tyro, Manual de Entrenamiento, Cap 20-21, 1978.