

UNIVERSIDAD POLITÉCNICA SALESIANA

SEDE QUITO

CARRERA: INGENIERÍA ELÉCTRICA

Tesis previa a la obtención del título de
INGENIERO ELÉCTRICO

**“APLICACIÓN DE REDES NEURONALES ARTIFICIALES EN EL
PRONÓSTICO DE LA DEMANDA ELÉCTRICA A CORTO PLAZO EN EL SNI”**

AUTOR:

DAVID ANDRÉS ORTIZ PARRA

DIRECTOR:

ING. SANTIAGO ESPINOSA

QUITO, 2014

DECLARATORIA DE AUTORÍA:

Yo, David Andrés Ortiz Parra autorizo a la Universidad Politécnica Salesiana la publicación total o parcial de este trabajo de grado y su reproducción sin fines de lucro.

A través de la presente declaración cedo el derecho de propiedad intelectual correspondiente de este trabajo a la Carrera de Ingeniería Eléctrica de la Universidad Politécnica Salesiana según lo establecido por la ley de propiedad intelectual, por su reglamento y por la normatividad institucional vigente.

Además declaro que los conceptos y análisis desarrollados y las conclusiones del presente trabajo son de exclusiva responsabilidad del autor.

Quito, 20 de Junio del 2014

David Andrés Ortiz Parra
CC: 1722860093

AUTOR

CERTIFICA:

Yo, Ing. Santiago Espinosa tutor, director de la tesis que titula “Aplicación de redes neuronales artificiales en el pronóstico de la demanda eléctrica a corto plazo en el S.N.F”, certifico, haber dirigido y revisado prolijamente cada uno de los capítulos técnicos y financieros, realizado por el Sr. David Andrés Ortiz Parra, previa a la obtención del título de Ingeniero Eléctrico en la Carrera de Ingeniería Eléctrica.

Por cumplir los requisitos autoriza su presentación.

Quito, 20 de Junio del 2014

Ing. Santiago Espinosa
DIRECTOR

DEDICATORIA

David Andrés Ortiz Parra

*Este proyecto es dedicado
Con mucho amor*

A mi Padre Eterno

*Por haberme dado la vida y regalarme cada día
la oportunidad de disfrutar de sus maravillas .*

A mis padres

A mi Madre Carmen Elena, por ser mi apoyo incondicional, por sus enseñanzas y valores, por su constante insistencia y perseverancia para convertir a sus hijos en personas de bien, por corregir mis faltas y celebrar mis triunfos, por su infinito amor y por haberme dado los regalos más grandes, el de regalarme la vida y el de darme la libertad para vivirla.

A mi Abuelita Emma mi otra Madre, que siempre estuvo junto a mí brindándome su amor, comprensión, y su fortaleza para siempre salir adelante a pesar de las adversidades de la vida.

A mi Abuelito Pepe, que fue más que un Padre, fue un amigo, un compañero en mi vida que me enseñó que la vida es una fiesta constante por medio de su ejemplo y su alegría, que durante este proceso se adelantó a reunirse con nuestro Padre eterno, pero estoy seguro que Él me acompaña en todos los momentos de mi vida.

A mi sobrino Ihan y a mi hermana Estefany, a mi hermana por siempre preocuparse y cuidar de mí, y a mi sobrino por ser mi fuente de inspiración y por brindarme su cariño y su alegría día a día.

A mis familiares.

A mi familia en general, porque me han brindado su apoyo incondicional, por estar siempre a mi lado y compartir conmigo buenos y malos momentos.

A mis amigos.

A Todos aquellos que creyeron en mí y me brindaron su apoyo en todo momento, y saben que sin ustedes la vida no sería tan emocionante.

AGRADECIMIENTO.

David Andrés Ortiz Parra

Principalmente agradezco a la prestigiosa Universidad Politécnica Salesiana la cual abrió sus puertas para prepararme de manera personal y académica, me brindó la oportunidad de adquirir conocimientos que me fueron útiles en el desarrollo del presente proyecto. A mis maestros quienes compartieron conmigo sus conocimientos y con su ejemplo me enseñaron valores para ser una persona de bien.

Un agradecimiento en especial a mí tutor y amigo Ing. Santiago Espinosa por colaborarme incondicionalmente con sus conocimientos en el desarrollo del proyecto de tesis.

Agradezco a mis amigos y compañeros de clase quienes siempre estuvieron para ser un apoyo y una alegría en el proceso de estudios en la universidad.

En general agradezco a todas y cada una de las personas que han estado presentes conmigo en la realización de la presente tesis, no necesito nombrar porque tanto ellas como yo sabemos que desde lo más profundo de mi corazón les agradezco el haberme brindado todo el apoyo, colaboración, ánimo y sobre todo cariño y amistad.

INDICE

DECLARATORIA DE AUTORÍA:	i
CERTIFICA:	ii
DEDICATORIA	iii
AGRADECIMIENTO	iv
INDICE	v
INDICE DE GRÁFICOS	viii
INDICE DE TABLAS	xii
NOMENCLATURA	xiv
ABREVIATURAS	xv
RESUMEN	xvi
ABSTRACT	xvii
INTRODUCCIÓN	1
CAPÍTULO I	2
ASPECTOS RELEVANTES SOBRE EL PRONÓSTICO DE LA DEMANDA ELÉCTRICA	2
1.1 Situación actual de Sector Eléctrico	2
1.1.1. Expansión de Generación	2
1.1.2. Expansión de la Trasmisión	13
1.1.3. Expansión de la distribución	16
1.2 Participación del CENACE en la operación del SNI	17
1.2.1 Función global	18
1.2.2 Funciones Específicas	18
1.3 Planificación del crecimiento de la demanda eléctrica y programación de la operación	19
1.3.1 Proyección de la demanda eléctrica	19
1.3.2. Proyección de la demanda eléctrica sector residencial	20
1.3.3. Proyección de la demanda eléctrica sector comercial	22
1.3.4. Proyección de la demanda eléctrica sector industrial	24
1.3.5. Proyección de la demanda eléctrica sector alumbrado público	25
1.3.6. Resultados de la demanda nacional	27
1.3.7. Programación de la operación, Análisis energético	30
1.4 Modelos de pronóstico utilizados en la actualidad	35
CAPÍTULO II	37

MÉTODOS DE PREDICCIÓN DE DEMANDA.....	37
2.1. Concepto y Clasificación de los métodos de predicción.	37
2.1.1. Conceptos.	37
2.1.2. Clasificación de los métodos de pronóstico.	38
2.2. Marco conceptual del sistema de pronóstico y sus criterios.....	41
2.2.1. Horizontes del tiempo de pronóstico.....	41
2.2.2. Marco conceptual del sistema de pronóstico.....	41
2.2.3 Criterios de pronóstico	42
2.3 Análisis de series temporales.....	45
2.3.1. Definición	45
2.3.2 Características de las series de tiempo.....	45
2.4 Redes Neuronales	50
2.4.3 Red de propagación hacia atrás (retropropagación)	51
2.4.2 El algoritmo de retropropagación.....	53
2.4.3 Optimización de la red neuronal.....	56
2.4.4 Variables de entrada del modelo de pronóstico.....	56
CAPÍTULO III	60
DESARROLLO DE LA APLICACIÓN UTILIZANDO REDES NEURONALES	60
3.1 Análisis de la demanda eléctrica.....	60
3.1.1 Análisis estadístico de los datos.	60
3.1.2 Función de distribución de probabilidad	62
3.1.3 Estadísticos principales empleados para el análisis en el pronóstico de demanda eléctrica a corto plazo (STLF).....	63
3.2 Identificación de valores atípicos y tratamiento.	64
3.2.1 Fuente de valores atípicos.	64
3.3 Clasificación de patrones y determinación de variables	71
3.4 Modelamiento matemático.....	71
3.4.1 Información Utilizada.....	71
3.4.2 Metodología de predicción desarrollada	74
3.4.3 Análisis de perfiles de carga diaria.....	75
3.4.4 Prueba de Grubbs para detectar valores atípicos en los datos de demanda eléctrica del periodo enero 2010 – mayo 2013	75
3.4.5 Diagrama de cajas aplicado en la serie de tiempo de la demanda eléctrica para la detección de valores atípicos.	77
3.4.6 Clasificación de patrones.....	78

3.4.7	Selección de las variables de entrada	78
3.4.8	Normalización y acondicionamiento	80
3.4.9	Estructura de la red neuronal.	80
3.4.10	Comparación pronostico Red Neuronal vs Regresión lineal.....	87
CAPÍTULO IV		89
ANÁLISIS DE RESULTADOS.....		89
4.1	Medición del error de pronóstico.....	89
4.2	Resultados de las predicciones utilizando el modelo de redes neuronales.	92
4.3	Comparación de medidas obtenidas con datos del operador	93
4.4	Factibilidad técnica-económica.	103
CONCLUSIONES.....		111
RECOMENDACIONES		115
REFERENCIAS		117
ANEXOS		119
ANEXO 1		120
ANEXO 2		123
ANEXO 3		126
ANEXO 4		131
ANEXO 5		136
ANEXO 6		140
ANEXO 7		144
ANEXO 8		149

INDICE DE GRÁFICOS

Gráfico 1 Cadena de suministro eléctrico.....	2
Gráfico 2. Evolución decenal de clientes por grupo de consumo 2003-2012.	6
Gráfico 3. Participación del consumo años 2003-2012.....	7
Gráfico 4. Evolución decenal de energía por grupo de consumo.	7
Gráfico 5. Reserva de energía, hidrología media	9
Gráfico 6. Reserva de Energía, hidrología semi-seca.....	9
Gráfico 7. Energía por tipo de tecnología, hidrología seca.	10
Gráfico 8. Reserva de energía, hidrología seca.	10
Gráfico 9. Balance de Energía en hidrología media.....	11
Gráfico 10. Evolución de la potencia instalada en el S.N.I., periodo 2013-2022.	12
Gráfico 11. Reserva de Potencia, periodo 2013-2022.....	12
Gráfico 12. Zonas Operativas del Sistema Nacional de Transmisión.	14
Gráfico 13. Composición de las líneas de transmisión del SNT	15
Gráfico 14. Evolución histórica y proyección de clientes del sector residencial.	21
Gráfico 15. Evolución histórica y proyección del consumo del sector residencial.....	22
Gráfico 16. Evolución histórica y proyección de clientes del sector comercial.....	23
Gráfico 17. Evolución histórica y proyección del consumo del sector comercial.	23
Gráfico 18. Evolución histórica y proyección de clientes del sector industrial.	24
Gráfico 19. Evolución histórica y proyección del consumo del sector industrial.	25
Gráfico 20. Evolución histórica y proyección de clientes del sector alumbrado público. ...	26
Gráfico 21. Evolución histórica y proyección del consumo del sector alumbrado público. ...	27
Gráfico 22. Evolución histórica y proyección de la facturación total de energía por grupo de consumo.....	28
Gráfico 23. Evolución histórica y proyección de la facturación total de energía en el Ecuador.....	28
Gráfico 24. Composición del mercado de distribución eléctrica del Ecuador, años 2012 y 2022.	29
Gráfico 25. Evolución histórica y proyección de clientes totales y por grupo de consumo del Ecuador.	30
Gráfico 26. Etapas de un sistema de pronóstico.....	42
Gráfico 27. Proceso para el desarrollo de pronóstico.....	43
Gráfico 28. Serie de tiempo.....	47

Gráfico 29. Serie Temporal con tendencia.	48
Gráfico 30. Serie temporal con componente estacional semanal	49
Gráfico 31. Serie temporal mensual cíclica.....	49
Gráfico 32. Serie temporal con componente aleatoria	50
Gráfico 33. Conexión entre una neurona de capa oculta con una neurona de salida	53
Gráfico 34. Estructura de red neuronal tipo MLP.	53
Gráfico 35. Representación de una neurona oculta o de salida.....	55
Gráfico 37. Función de densidad de probabilidad 18hs. Lunes-Viernes.....	61
Gráfico 38. Función de distribución acumulativa.	61
Gráfico 39. Diagrama de cajas para las 14 horas del periodo 03/01/2011-23/01/2011.....	66
Gráfico 40. Estimación de valores atípicos de una muestra de 21 valores, correspondientes a la demanda de las 14:00 del período 03/01/2011-23/01/2011, con media = 2224,5 y S = 199,98814.	68
Gráfico 41. Serie de tiempo de demanda eléctrica periodo 01-ene-2010 a 31-dic-2010 que se utilizará en el pronóstico de corto plazo.....	72
Gráfico 42. Serie de tiempo de demanda eléctrica periodo 01-ene-2011 a 31-dic-2011 que se utilizará en el pronóstico de corto plazo.....	73
Gráfico 43. Serie de tiempo de demanda eléctrica periodo 01-ene-2012 a 31-dic-2012 que se utilizará en el pronóstico de corto plazo.....	73
Gráfico 44. Serie de tiempo de demanda eléctrica periodo 01-ene-2013 a 24-may-2013 que se utilizará en el pronóstico de corto plazo.....	74
Gráfico 45. Perfil de demanda diaria para el período diciembre2012-enero2013.....	75
Gráfico 46. Prueba de Grubbs para la detección de valores atípicos.	76
Gráfico 47. Diagrama de cajas utilizado para la detección de valores atípicos de la serie de tiempo de demanda eléctrica período enero 2010 – 24 de mayo 2013.....	77
Gráfico 48. Comparación de perfiles de carga para días laborales de la época seca y lluviosa.	78
Gráfico 49. Estructura de red neuronal utilizada para el pronóstico de demanda de energía eléctrica en corto plazo en el SNI, sin variables del clima como entrada a la red, Caso1....	82
Gráfico 50. Estructura de red neuronal utilizada para el pronóstico de demanda de energía eléctrica en corto plazo en el SNI, incluyendo las variables del clima como entrada a la red, Caso2	83
Gráfico 51. Proceso de aprendizaje de la red neuronal para el pronóstico de demanda de energía eléctrica en corto plazo en el SNI, sin variables del clima como entrada a la red, Caso1	84
Gráfico 52. Proceso de aprendizaje de la red neuronal para el pronóstico de demanda de energía eléctrica en corto plazo en el SNI, incluyendo las variables del clima como entrada a la red, Caso2	85

Gráfico 53. Diagrama de la metodología de pronóstico de la demanda de energía eléctrica a corto plazo propuesta.....	86
Gráfico 54. Comparación del pronóstico de regresión lineal vs pronóstico de redes neuronales.....	88
Gráfico 55. Diferencia entre el valor de demanda real y demanda pronosticada, caso1.....	90
Gráfico 56. Diferencia entre el valor de demanda real y demanda pronosticada, caso2.....	91
Gráfico 56. Gráfica comparativa de la demanda real y los valores de pronóstico periodo 01-ene-2010 a 24-may-2013, caso1.....	92
Gráfico 57. Gráfica comparativa de la demanda real y los valores de pronóstico periodo 01-ene-2010 a 24-may-2013, caso2.....	92
Gráfico 58. Comparación de la demanda real con los valores pronosticados del 25-mayo-2013, caso1.....	94
Gráfico 59. Comparación de la demanda real con los valores pronosticados del 25-mayo-2013, caso2.....	94
Gráfico 60. Comparación de la demanda real con los valores pronosticados del 26-mayo-2013, caso1.....	95
Gráfico 61. Comparación de la demanda real con los valores pronosticados del 26-mayo-2013, caso2.....	96
Gráfico 62. Comparación de la demanda real con los valores pronosticados del 27-mayo-2013, caso1.....	97
Gráfico 63. Comparación de la demanda real con los valores pronosticados del 27-mayo-2013, caso2.....	97
Gráfico 64. Comparación de la demanda real con los valores pronosticados del 28-mayo-2013, caso1.....	98
Gráfico 65. Comparación de la demanda real con los valores pronosticados del 28-mayo-2013, caso2.....	99
Gráfico 66. Comparación de la demanda real con los valores pronosticados del 29-mayo-2013, caso1.....	100
Gráfico 67. Comparación de la demanda real con los valores pronosticados del 29-mayo-2013, caso2.....	100
Gráfico 68. Comparación de la demanda real con los valores pronosticados del 30-mayo-2013, caso1.....	101
Gráfico 69. Comparación de la demanda real con los valores pronosticados del 30-mayo-2013, caso2.....	102
Gráfico 70. Demanda Real vs Resultados de los pronósticos y predespacho, 25 de mayo 2013. Gráfico.....	104
Gráfico 71. Demanda Real vs Resultados de los pronósticos y predespacho, 26 de mayo 2013.....	105

Gráfico 72. Demanda Real vs Resultados de los pronósticos y predespacho, 27 de mayo 2013.	106
Gráfico 73. Demanda Real vs Resultados de los pronósticos y predespacho, 28 de mayo 2013.	107
Gráfico 74. Demanda Real vs Resultados de los pronósticos y predespacho, 29 de mayo 2013.	108
Gráfico 75. Demanda Real vs Resultados de los pronósticos y predespacho, 30 de mayo 2013.	109

INDICE DE TABLAS

Tabla 1. Infraestructura existente en generación hidroeléctrica y renovable no convencional, año 2012	4
Tabla 2 Infraestructura existente en Generación termoeléctrica a diciembre 2012	5
Tabla 3. Empresas de Distribución.....	17
Tabla 4. Expectativa del crecimiento de la demanda eléctrica.....	20
Tabla 5. Empresas de distribución de energía eléctrica.....	31
Tabla 6. Empresas de distribución de energía eléctrica.....	31
Tabla 7. Empresas autogeneradoras.	32
Tabla 8. Incorporación de proyectos de generación.	33
Tabla 9. Tasa de crecimiento promedio anual de potencia y energía periodo abril 2013-marzo 2014.	33
Tabla 10. Resumen de proyección mensual de potencia y energía en bornes de generador, periodo abril 2013 - marzo 2014.	34
Tabla 11. Intervalos de confianza.....	63
Tabla 12. Matriz de correlación de la demanda diaria de energía eléctrica de la serie de tiempo del periodo 03/01/2012 a 09/01/2012.....	64
Tabla 13. Datos que se utilizaran para realizar el análisis de cuartiles, diagrama de cajas y prueba de Grubbs.....	66
Tabla 14. Límites de rango de valores atípicos moderados y rango de valores atípicos extremos	66
Tabla 15. Variables de entrada a la red neuronal.	79
Tabla 16. Matriz de predictores, datos de entrada a la Red Neuronal, caso 1	79
Tabla 17. Matriz de predictores, datos de entrada a la Red Neuronal, caso 2.....	80
Tabla 18. Análisis para elegir el número de neuronas en la capa oculta para la red neuronal, caso1 sin incluir la variable del clima como entrada a la red.	81
Tabla 19. Análisis para elegir el número de neuronas en la capa oculta para la red neuronal, caso2 incluyendo la variable del clima como entrada a la red.	81
Tabla 20. Parámetros para el aprendizaje de la red neuronal para el pronóstico de demanda de energía eléctrica en corto plazo en el SNI, sin variables del clima como entrada a la red, Caso1.	83
Tabla 21. Parámetros para el aprendizaje de la red neuronal para el pronóstico de demanda de energía eléctrica en corto plazo en el SNI, incluyendo las variables del clima como entrada a la red, Caso2.....	84
Tabla 22. Comparación de pronósticos de series de tiempo vs redes neuronales.	88
Tabla 23. Medidas de error del pronóstico de demanda de energía eléctrica en corto plazo, caso1.	89

Tabla 24. Medidas de error del pronóstico de demanda de energía eléctrica en corto plazo, caso2.	89
Tabla 25. Cuadro comparativo de las medidas de error de los pronósticos de demanda en el corto plazo para los dos casos en estudio, respecto a la demanda real, 25-may-2013.	95
Tabla 26. Cuadro comparativo de las medidas de error de los pronósticos de demanda en el corto plazo para los dos casos en estudio, respecto a la demanda real, 26-may-2013.	96
Tabla 27. Cuadro comparativo de las medidas de error de los pronósticos de demanda en el corto plazo para los dos casos en estudio, respecto a la demanda real, 27-may-2013.	98
Tabla 28. Cuadro comparativo de las medidas de error de los pronósticos de demanda en el corto plazo para los dos casos en estudio, respecto a la demanda real, 28-may-2013.	99
Tabla 29. Cuadro comparativo de las medidas de error de los pronósticos de demanda en el corto plazo para los dos casos en estudio, respecto a la demanda real, 29-may-2013.	101
Tabla 30. Cuadro comparativo de las medidas de error de los pronósticos de demanda en el corto plazo para los dos casos en estudio, respecto a la demanda real, 30-may-2013.	102
Tabla 31. Precios en barra de mercado de los periodos de demanda base, media y punta, 25-may-2013 a 30-may-2013.....	103
Tabla 32. Cuadro comparativo de las medidas de error de pronóstico 2013-05-25.....	104
Tabla 33. Cuadro comparativo económico 2013-05-25.....	104
Tabla 34. Cuadro comparativo de las medidas de error de pronóstico 2013-05-26.....	105
Tabla 35. Cuadro comparativo económico 2013-05-26.....	105
Tabla 36. Cuadro comparativo de las medidas de error de pronóstico 2013-05-27.....	106
Tabla 37. Cuadro comparativo económico 2013-05-27.....	106
Tabla 38. Cuadro comparativo de las medidas de error de pronóstico 2013-05-28.....	108
Tabla 39. Cuadro comparativo económico 2013-05-28.....	108
Tabla 40. Cuadro comparativo de las medidas de error de pronóstico 2013-05-29.....	108
Tabla 41. Cuadro comparativo económico 2013-05-29.....	109
Tabla 42. Cuadro comparativo de las medidas de error de pronóstico 2013-05-30.....	109
Tabla 43. Cuadro comparativo económico 2013-05-30.....	110

NOMENCLATURA

Y_t	Valor de respuesta de salida en el tiempo t .
t	Instante de tiempo en que se observa un valor, o fenómeno específico.
L_t	Componente de nivel de una señal a lo largo del tiempo, se refiere al valor constante en el tiempo.
m_t	Componente de la pendiente o tendencia de una función que integra a una señal.
S_t	Componente estacional de una función que describe a una señal en el tiempo.
E_t, e_t, ε_t	Diferencia de los valores de dos funciones, en el mismo instante t , también definida como error pronóstico
X_0	Valores asignados a las condiciones iniciales de las variables de entrada al proceso.
$\mu_{\widehat{Y}_0}$	Valor de la media esperada o esperanza matemática estimada, pronóstico o predicción
$\sigma_{\widehat{Y}_0}$	Varianza del valor con respecto a la media de la variable estimada
N, n	Número de valores considerados en el análisis
$f(\cdot)$	Operador funcional de activación de las neuronas en cada capa
$P(X = x)$	Probabilidad de ocurrencia
Cov	Covarianza de dos o más variables aleatorias
Σ	Sumatoria de un conjunto de valores
w_{ji}	Matriz de valores de los pesos de conexión entre neuronas
\bar{x}_{err}	Media del error de pronóstico
M_{ed}	Mediana del error de pronóstico
S_{err}	Desviación estándar del error

ABREVIATURAS

S.N.I	Sistema Nacional Interconectado.
CENACE	Centro Nacional de Control de Energía.
PEG	Plan de Expansión de Generación.
CELEC EP	Corporación Eléctrica del Ecuador.
CONELEC	Consejo Nacional de electricidad.
INAMHI	Instituto Nacional de meteorología e hidrología.
FERUM	Programa de energización rural y electrificación urbano-marginal
S.N.T	Sistema Nacional de Transmisión.
MW	Megavatio.
kV	Kilovoltios.
MVA	Mega-voltio amperio.
GWh	Gigavatios-hora.
ANN	Red Neuronal Artificial (Artificial Neural Network)
DTS	Desviación T de Student
FDP	Función de Distribución de Probabilidad.
FFNN	Red Neuronal de Alimentación hacia Adelante (Feedforward Neural Network)
MAE	Error Medio Absoluto (Mean Absolute Error)
MAPE	Porcentaje del Error Medio Absoluto (Mean Absolute Percentage Error)
ME	Promedio del Error (Mean Error)
MSE	Error Cuadrático Medio (Mean Square Error)
SOM	Mapas Auto Organizados (Self Organizing Maps)
SSE	Suma del Error Cuadrático (Sum of Squared Error)
STLF	Pronóstico de Demanda a Corto Plazo (Short Term Load Forecasting)
ADALINE	Elemento lineal adaptativo (Adaptive Linear Element)
MADALINE	Multiples elementos lineales adaptativos (Multiple Adaptive Linear Element)
FIR	Razonamiento Inductivo Fuzzy (Fuzzy Inductive Reasoning)
MLP	Perceptrón Multicapa (Multilayer Perceptron)

RESUMEN

APLICACIÓN DE REDES NEURONALES ARTIFICIALES EN EL PRONÓSTICO DE LA DEMANDA ELÉCTRICA A CORTO PLAZO EN EL SNI.

David Andrés Ortiz Parra.

and3_davids@hotmail.com

Universidad Politécnica Salesiana

Resumen—“En el presente trabajo de tesis brinda una solución a la predicción de la demanda eléctrica en corto en el SNI usando modelos de redes neuronales.

Con la aplicación de las Redes Neuronales Artificiales, se resuelve el problema de la complejidad de los modelos de predicción tradicionales, a partir de los factores que realmente afectan el consumo energético, los aspectos que se consideraran en este estudio particularmente son: i) Datos históricos de demandas eléctricas diarias, ii) Datos del clima; y, iii) Datos del tiempo como son la hora y la fecha. Con el algoritmo de solución desarrollado se realiza el análisis en dos casos, el primer caso realizara la predicción en el SNI incluyendo únicamente el comportamiento de la demanda y el segundo caso realiza la predicción de la demanda eléctrica en el SNI tomando en cuenta el caso anterior y además se incluye la variable del clima”.

Palabras Claves— Pronóstico de demanda eléctrica de corto plazo, redes neuronales artificiales.

ABSTRACT

APPLICATION OF ARTIFICIAL NEURAL NETWORKS IN THE SHORT TERM LOAD FORECASTING, IN THE SNI.

David Andrés Ortiz Parra.

and3_dauids@hotmail.com

Universidad Politécnica Salesiana

Summary - "The present thesis provides a solution to the forecasting of electricity demand in the short SNI using neural network models.

With the application of Artificial Neural Networks , the problem of the complexity of traditional prediction models is solved , from factors that actually affect energy consumption, aspects that were considered in this study are particularly : i) historical data daily electrical demand , ii) climate data ; and , iii) weather such as time and date . With the developed solution algorithm analysis is performed in two cases , the first case perform the prediction on the SNI including only the behavior of the application and the second case takes the prediction of electricity demand in the SNI taking into account the previous case and variable climate also included ."

Keywords - Forecast electricity demand short-term, artificial neural networks.

INTRODUCCIÓN

En la actualidad el pronóstico de la demanda eléctrica es una tarea que implica gran responsabilidad y complejidad, ya que tras de ella conlleva repercusiones importantes para los Operadores del Sistema y Agentes del Sector Eléctrico, es así que bajo este entorno, el pronóstico de la demanda eléctrica debería disminuir todas las incertidumbres, es decir que debe existir compatibilidad entre la calidad del servicio y la asignación de los recursos. En este sentido, el pronóstico de la demanda de energía eléctrica a corto plazo es una función esencial para una confiable y económica operación del sistema de potencia ecuatoriano.

El pronóstico de la demanda de energía eléctrica en el corto plazo comprende un intervalo de 24 horas y es de vital importancia para diferentes procesos realizados por el Centro Nacional de Control de Energía (CENACE) tales como: el despacho económico y la programación de transferencia de energía y el control en tiempo real[1].El costo de operación del sistema eléctrico de potencia ecuatoriano se ve afectado por varios factores, uno de estos factores es el error en la predicción de la demanda eléctrica ya que sin una correcta representación de las necesidades futuras de generación de energía eléctrica, los problemas por exceso de capacidad o insuficiencia de capacidad, pueden tener costos elevados para el sistema.

Debido a esto surge la necesidad de buscar nuevos métodos que permitan obtener predicciones de demanda de eléctrica con niveles de error mínimos con respecto a los niveles reales.

CAPÍTULO I

ASPECTOS RELEVANTES SOBRE EL PRONÓSTICO DE LA DEMANDA ELÉCTRICA

En este capítulo se tratará sobre la situación actual del sector eléctrico ecuatoriano, la participación del operador del sistema (CENACE) en la operación de Sistema Nacional Interconectado, así como la planificación del crecimiento de la demanda eléctrica de corto plazo y la programación de la operación, además se tratará sobre los modelos de predicción de demanda eléctrica que utiliza en la actualidad el operador del sistema.

1.1 Situación actual de Sector Eléctrico

La situación actual del sector eléctrico ecuatoriano se presentará, enfocándose a los principales indicadores de gestión técnica y económica-financiera de la industria eléctrica, incluyendo información histórica y estadística.

La cadena de suministro eléctrico dispone de las siguientes etapas, Gráfico 1.[2]




Gráfico 1 Cadena de suministro eléctrico

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2012 – 2021, capítulo 1 Introducción, 1.1 Antecedentes.

1.1.1. Expansión de Generación

El parque generador en el Ecuador dispone de 16 centrales hidroeléctricas estatales de pequeña, mediana y gran capacidad (1 - 1.100 MW) y 39 centrales pequeñas pertenecientes

a las empresas de distribución eléctrica, a municipios y a empresas privadas.¹

En la Tabla 1 y Tabla 2 se indican las características de la infraestructura de centrales hidroeléctricas, convencionales no renovables y termoeléctricas con información levantada a diciembre de 2012.

No.	EMPRESA	CENTRAL HIDROELÉCTRICA	UNIDADES	POTENCIA EFECTIVA (MW)	ENERGÍA MEDIA (GWh/año)	PLANTA (%)
1	CELEC EP HIDROPAUTE	PAUTE	10	1100	5865,00	62,28
2	CELEC EP HIDROAGOYÁN	SAN FRANCISCO	2	216	914,00	45,30
3	CELEC EP HIDRONACIÓN	DAULE PERIPA	3	213	1050,00	56,30
4	CELEC EP HIDROPAUTE	MAZAR	2	163	908,40	61,00
5	CELEC EP HIDROAGOYÁN	AGOYÁN	2	156	1010,00	73,90
6	CELEC EP HIDROAGOYÁN	PACARÁ	2	73	149,40	23,40
7	E.E. QUITO	CUMBAYÁ	4	40	181,09	52,40
8	HIDROABANICO	HIDROABANICO	5	37,5	325,00	97,70
9	E.E. QUITO	NAYÓN	2	29,7	151,14	58,90
10	ELECAUSTRO	OCAÑA	2	26	203,00	89,00
11	ELECAUSTRO	SAUCAY	4	24	141,42	68,20
12	E.E. QUITO	GUANGOPOLO	6	20,92	86,40	47,80
13	ENERMAX	CALOPE	2	18	90,00	62,50
14	HIDROSIBIMBE	SIBIMBE	1	15	89,25	63,70
15	EMAAP-Q	RECUPERADORA	1	14,5	102,60	81,90
16	ELECAUSTRO	SAYMIRIN	6	14,4	96,26	77,20
17	E.E. RIOBAMBA	ALAO	4	10	69,12	80,00
18	E.E. COTOPAXI	ILLUCHI 1-2	6	9,2	47,69	60,00
19	EMAAP-Q	EL CÁRMEN	1	8,2	36,77	51,90
20	E.E. NORTE	AMBI	2	8	34,56	50,00
21	ECOLUZ	PAPALLACTA	2	6,2	23,62	44,10
22	MANAGENERACIÓN	ESPERANZA	1	6	19,00	-
23	LA INTERNACIONAL	VINDOBONA	3	5,86	32,66	64,50
24	E.E. QUITO	PASOCHOA	2	4,5	24,03	61,80
25	MANAGENERACIÓN	POZA HONDA	1	3	16,00	-
26	E.E. RIOBAMBA	RÍO BLANCO	1	3	18,09	69,80
27	PERLABÍ	PERLABÍ	1	2,46	13,09	61,60
28	E.E. SUR	CARLOS MORA	3	2,4	17,00	82,00

¹ PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, resumen ejecutivo, capítulo 3 expansión de generación, 3.3. Potencia Instalada y Disponible del S.N.I, pág. 20, párrafo 1.

29	ECOLUZ	LORETO	1	2,15	12,97	69,80
30	E.E. NORTE	BUENOS AIRES	1	1	7,00	80,00
31	HIDROSIBIMBE	CORAZÓN	1	0,98	7,62	90,00
32	-	Otras Menores	24	21,97	94,91	50,00
Total			108	2256,00	11837,00	

No.	EMPRESA	CENTRAL DE ENERGÍA RENOVABLE NO CONVENCIONAL	UNIDADES	POTENCIA EFECTIVA (MW)	ENERGÍA MEDIA (GWh/año)
1	ECOELECTRIC	ECOELECTRIC	3	35,20	110,84
2	SAN CARLOS	SAN CARLOS	4	30,60	87,72
3	ECUDOS	ECUDOS A - G	4	27,60	97,80
4	GENSUR	VILLONACO	11	16,50	-
Total			22	109,90	296,36

Tabla 1. Infraestructura existente en generación hidroeléctrica y renovable no convencional, año 2012

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, resumen ejecutivo, capítulo 3 expansión de generación.

No.	EMPRESA	CENTRAL	TIPO	POTENCIA NOMINAL (MW)	POTENCIA EFECTIVA (MW)	ENERGÍA NETA (GWh/año)
1	ELECTROGUAYAS	ENRIQUE GARCÍA	Térmica Turbogas	102,00	93,00	142,09
2		G. ZEVALLOS TG4	Térmica Turbogas	26,27	20,00	1,33
3		G. ZEVALLOS TV2-TV3	Térmica Turbovapor	146,00	146,00	685,74
4		SANTA ELENA 2	Térmica MCI	90,10	90,10	388,01
5		SANTA ELENA 3	Térmica MCI	41,70	41,70	98,53
6		TRINITARIA	Térmica Turbovapor	133,00	133,00	629,48
1	TERMOESMERALDAS	JARAMIJÓ	Térmica MCI	140,00	138,50	457,82
2		C. LA PROPICIA 1-2-3	Térmica MCI	10,50	9,60	16,14
3		MANTA 2	Térmica MCI	20,40	19,20	94,53
4		MIRAFLORES	Térmica MCI	29,50	24,00	27,93
5			Térmica Turbogas	22,80	19,00	30,26
6		PEDERNALES	Térmica MCI	2,50	2,00	1,25
7		ESMERALDAS	Térmica Turbovapor	132,50	131,00	755,35
1	TERMO GAS MACHALA	MACHALA 1	Térmica Turbogas	140,00	128,50	813,28
2		MACHALA 2	Térmica Turbogas	136,80	124,00	406,64
1	TERMOPICHINCHA	CAMPO ALEGRE	Térmica MCI	0,40	0,36	0,51
2		CELSO CASTELLANOS	Térmica MCI	7,50	5,70	5,51
3		GUANGOPOLO	Térmica MCI	17,52	16,80	68,07
4		JIVINO	Térmica MCI	5,00	3,80	0,51
5		JIVINO 2	Térmica MCI	10,20	10,00	8,19

6		JIVINO 3	Térmica MCI	40,00	36,00	170,83
7		PAYAMINO	Térmica MCI	4,08	2,70	0,08
8		PUNÁ NUEVA	Térmica MCI	3,37	3,15	2,18
9		PUNÁ VIEJO	Térmica MCI	0,07	0,06	0,10
10		QUEVEDO2	Térmica MCI	102,00	100,00	474,30
11		SACHA	Térmica MCI	20,40	18,00	74,23
12		SANTA ELENA	Térmica MCI	40,00	40,00	8,92
13		SANTA ROSA 1-2-3	Térmica Turbogas	51,30	51,00	17,90
14		SECOYA	Térmica MCI	11,40	10,00	25,95
1	Elecaastro	EL DESCANSO	Térmica MCI	19,20	17,20	67,50
1	Electroquil	ELECTROQUIL U1-U2-U3-U4	Térmica Turbogas	181,00	181,00	217,06
1	Generoca Intervisa Trade	GENEROCA1-2-3-4-5-6-7-8	Térmica MCI	38,12	34,33	121,41
1	Termoguayas	VICTORIA 2	Térmica Turbogas	115,00	102,00	60,54
1	Termoguayas	TERMOGUAYAS	Térmica MCI	150,00	120,00	546,45
1	E.E. Ambato	LLIGUA	Térmica MCI	5,00	3,30	0,42
1	E.E. Centro Sur	CENTRAL TÉRMICA TAISHA	Térmica Turbovapor	0,24	0,24	0,34
1	EEQ SA	GUALBERTO HERNANDEZ	Térmica MCI	34,32	31,20	142,15
1	Regional Sur	CATAMAYO	Térmica MCI	19,74	17,17	9,82
1	Eléctrica de Guayaquil CNEL-Sucumbios	ALVARO TINAJERO 1-2	Térmica Turbogas	94,80	81,50	121,81
2		ANIBAL SANTOS G.1-2-3-5-6	Térmica Turbogas	106,77	97,50	40,72
3		ANIBAL SANTOS V.	Térmica Turbovapor	34,50	33,00	207,09
1		NUEVO ROCAFUERTE	Térmica MCI	0,45	0,37	0,31
2		PUERTO EL CARMEN	Térmica MCI	0,65	0,45	2,93
3		TIPUTINI	Térmica MCI	0,16	0,12	0,60
Total		43	Total	2287,26	2136,55	6944,81

Tabla 2 Infraestructura existente en Generación termoeléctrica a diciembre 2012

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, vol1, resumen ejecutivo, capítulo 3 expansión de generación.

1.1.1.1 Estructura y Evolución del sector eléctrico

El comportamiento de la demanda eléctrica está marcada por la cantidad de potencia y el horario de consumo, es decir al grupo de consumo al que pertenece (residencial, comercial, industrial y alumbrado público), en el Gráfico 2 se muestra cómo ha evolucionado el número de clientes.





Gráfico 2. Evolución decenal de clientes por grupo de consumo 2003-2012.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, estudio y gestión de la demanda eléctrica, capítulo 3 la demanda y el sector eléctrico ecuatoriano.



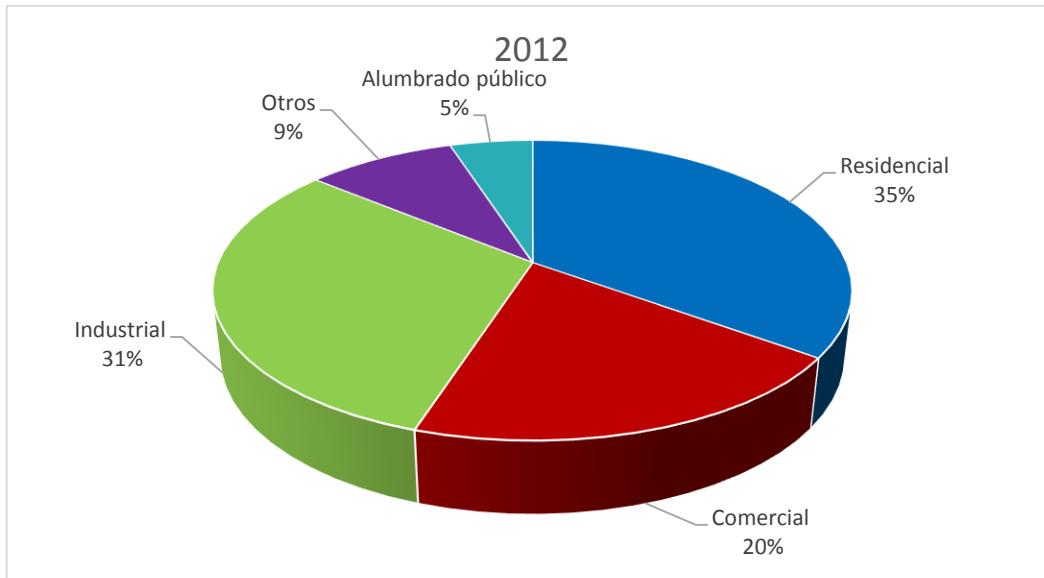


Gráfico 3. Participación del consumo años 2003-2012

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, estudio y gestión de la demanda eléctrica, capítulo 3 la demanda y el sector eléctrico ecuatoriano; modificaciones del autor.

En el Gráfico 3 se muestra la estructura de participación entre los años 2003-2012, se observa que la mayor participación es del sector industrial y comercial.

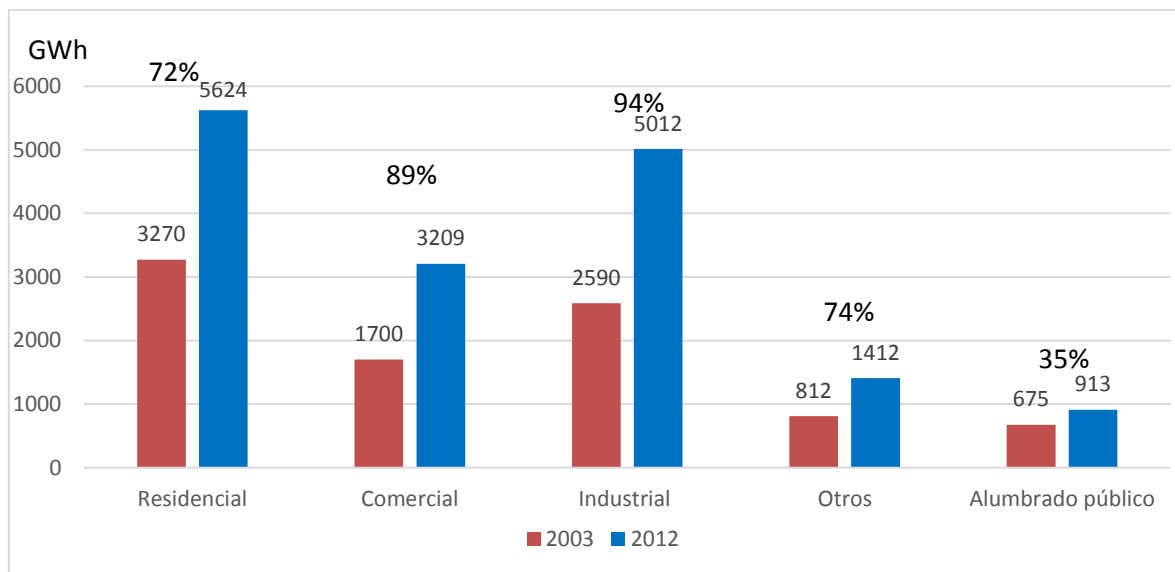


Gráfico 4. Evolución decenal de energía por grupo de consumo.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, estudio y gestión de la demanda eléctrica, capítulo 3 la demanda y el sector eléctrico ecuatoriano.

La categoría que presentó mayor incremento en el consumo de energía es la categoría industrial con un 94%, mientras que la categoría comercial experimentó un crecimiento del

89%, seguida de la categoría residencial con un 72%, la categoría de otros con un 74% y la categoría de alumbrado público es la categoría que presenta el menor incremento con un 35%, esto se muestra en el Gráfico 4.

1.1.1.2 Reserva de energía

El criterio adoptado en el actual plan de expansión de generación, es de garantizar una reserva mínima energía del 10% ante la ocurrencia de un escenario hidrológico seco y una reserva mínima de potencia del 20%, sin conexiones internacionales.

A continuación se presentan los resultados de las reservas de energía considerando precios internacionales de combustibles, para los siguientes escenarios:

- **Escenario hidrológico promedio**

En el caso de presentarse un escenario hidrológico promedio, se muestra el gráfico de la oferta y demanda para el PEG 2013 - 2022 propuesto, en el que se identifica la composición según el tipo de tecnología, siendo predominante la generación hidroeléctrica especialmente desde la entrada en operación del proyecto hidroeléctrico Coca Codo Sinclair².

² PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, perspectiva y expansión del sistema eléctrico ecuatoriano, capítulo 2 expansión de la generación, 2.14 reservas energéticas y consumo de combustible periodo 2013-2022, pág. 39, párrafo 1.




Gráfico 5. Reserva de energía, hidrología media

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 3, perspectiva y expansión del sistema eléctrico ecuatoriano, capítulo 2 Expansión de la generación, subcapítulo 2.14 Reservas Energéticas y Consumo de Combustibles, Periodo 2013 – 2022, 2.14.1 Reserva de energía.

En el Gráfico 5 se observa que los niveles de reserva se ubican entre el 20% y el 52%.

- **Escenario hidrológico semi – seco (75% de probabilidad de excedencia)**

Para el caso de un escenario hidrológico intermedio, entre promedio y seco, se presenta el Gráfico 6 en el que se observa que los niveles de reserva se ubican entre el 11% y el 51%.




Gráfico 6. Reserva de Energía, hidrología semi-seca

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 3, perspectiva y expansión del sistema eléctrico ecuatoriano, capítulo 2 Expansión de la generación, subcapítulo 2.14 Reservas Energéticas y Consumo de Combustibles, Periodo 2013 – 2022, 2.14.1 Reserva de energía.

- **Escenario hidrológico seco (90 % de probabilidad de excedencia)**

Para el caso de un escenario hidrológico seco, en el Gráfico 7 se observa la demanda y oferta de energía eléctrica; en este caso, el componente térmico tiene una participación importante.




Gráfico 7. Energía por tipo de tecnología, hidrología seca.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 3, perspectiva y expansión del sistema eléctrico ecuatoriano, capítulo 2 Expansión de la generación, subcapítulo 2.14 Reservas Energéticas y Consumo de Combustibles, Periodo 2013 – 2022, 2.14.1 Reserva de energía.




Gráfico 8. Reserva de energía, hidrología seca.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 3, perspectiva y expansión del sistema eléctrico ecuatoriano, capítulo 2 Expansión de la generación, subcapítulo 2.14 Reservas Energéticas y Consumo de Combustibles, Periodo 2013 – 2022, 2.14.1 Reserva de energía.

En el Gráfico 8 se observa que durante algunos meses del periodo de análisis (enero 2013 – diciembre 2022) los niveles de reserva disminuyen bajo el umbral del 10%, sin embargo se ubican siempre sobre el 5%. Esta situación puede ser superada con el manejo de los embalses, especialmente en el periodo octubre – marzo, con el objeto de incrementar los niveles estimados. Se debe considerar que, el gráfico muestra el caso crítico, tanto para el crecimiento de la demanda, como para el escenario hidrológico; además, no se consideran las interconexiones internacionales con Colombia y Perú, las que en la práctica incrementarían los niveles de reserva.

El gráfico de balance energético entre oferta y demanda, para el periodo 2013 - 2022, ante condiciones hidrológicas medias se presenta a continuación³:




Gráfico 9. Balance de Energía en hidrología media

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 3, perspectiva y expansión del sistema eléctrico ecuatoriano, capítulo 2 Expansión de la generación, subcapítulo 2.14 Reservas Energéticas y Consumo de Combustibles, Periodo 2013 – 2022, 2.14.1 Reserva de energía.

1.1.1.3 Reserva de Potencia.

En relación a la reserva de potencia, se presentan dos gráficos, el uno corresponde a la evolución de la potencia instalada en el periodo 2013-2022, y otro que corresponde a la demanda máxima de potencia.[3]

³ PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 3, perspectiva y expansión del sistema eléctrico ecuatoriano, capítulo 2 Expansión de la generación, subcapítulo 2.14 Reservas Energéticas y Consumo de Combustibles, Periodo 2013 – 2022, 2.14.1 Reserva de energía, párrafo 6, pág. 42.

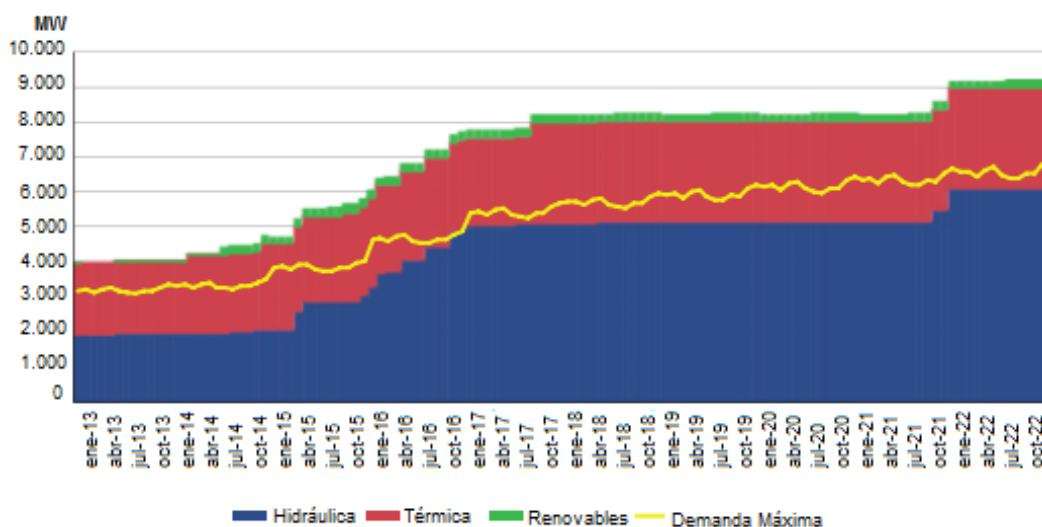


Gráfico 10. Evolución de la potencia instalada en el S.N.I., periodo 2013-2022.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 3, perspectiva y expansión del sistema eléctrico ecuatoriano, capítulo 2 Expansión de la generación, subcapítulo 2.14 Reservas Energéticas y Consumo de Combustibles, Periodo 2013 – 2022, 2.14.2 Reserva de Potencia.




Gráfico 11. Reserva de Potencia, periodo 2013-2022

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 3, perspectiva y expansión del sistema eléctrico ecuatoriano, capítulo 2 Expansión de la generación, subcapítulo 2.14 Reservas Energéticas y Consumo de Combustibles, Periodo 2013 – 2022, 2.14.2 Reserva de Potencia.

El criterio adoptado para el presente plan de expansión de generación, es el de garantizar, en lo posible, una reserva mínima de energía del 10% ante la ocurrencia de un escenario hidrológico seco (90 % de probabilidad de excedencia), y una reserva mínima de potencia del 20%, sin interconexiones internacionales.

En el Gráfico 10 se identifica la composición según el tipo de tecnología, siendo predominante la generación hidroeléctrica especialmente desde la entrada en operación del proyecto hidroeléctrico Coca Codo Sinclair.

En relación a la reserva de potencia, el margen adoptado es de al menos un 20%.

En el Gráfico 11 se observa el comportamiento de la reserva de potencia en el periodo 2013 - 2022. Durante todo el periodo se tendrían niveles de reserva superiores al 20%. [3]

1.1.2 Expansión de la Trasmisión.

El plan de expansión es elaborado con una visión integral de país, priorizando la atención de la demanda, cuya proyección incluye a más del crecimiento tendencial del consumo, la incorporación de importantes cargas al sistema, el cambio de la matriz energética y la necesidad de interconectar el sector petrolero con el Sistema Nacional de Transmisión⁴.

A continuación se detalla el plan de expansión elaborado por CELEC EP a través de la unidad de negocio TRANSELECTRIC que asegura la continuidad de la operación de la red de transmisión hasta finales del periodo de planificación (2013 - 2022), cumpliendo con las exigencias establecidas en las regulaciones vigentes, permitiendo la incorporación al sistema de los nuevos proyectos de generación definidos y garantizando el suministro de energía eléctrica a los centros de distribución⁵.

⁴ PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 3, perspectiva y expansión del sistema eléctrico ecuatoriano, capítulo 3 expansión de la transmisión, 3.1 Introducción, párrafo 3, pág. 55

⁵ PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 3, perspectiva y expansión del sistema eléctrico ecuatoriano, capítulo 3 expansión de la transmisión, 3.1 Introducción, párrafo 4, pág. 55

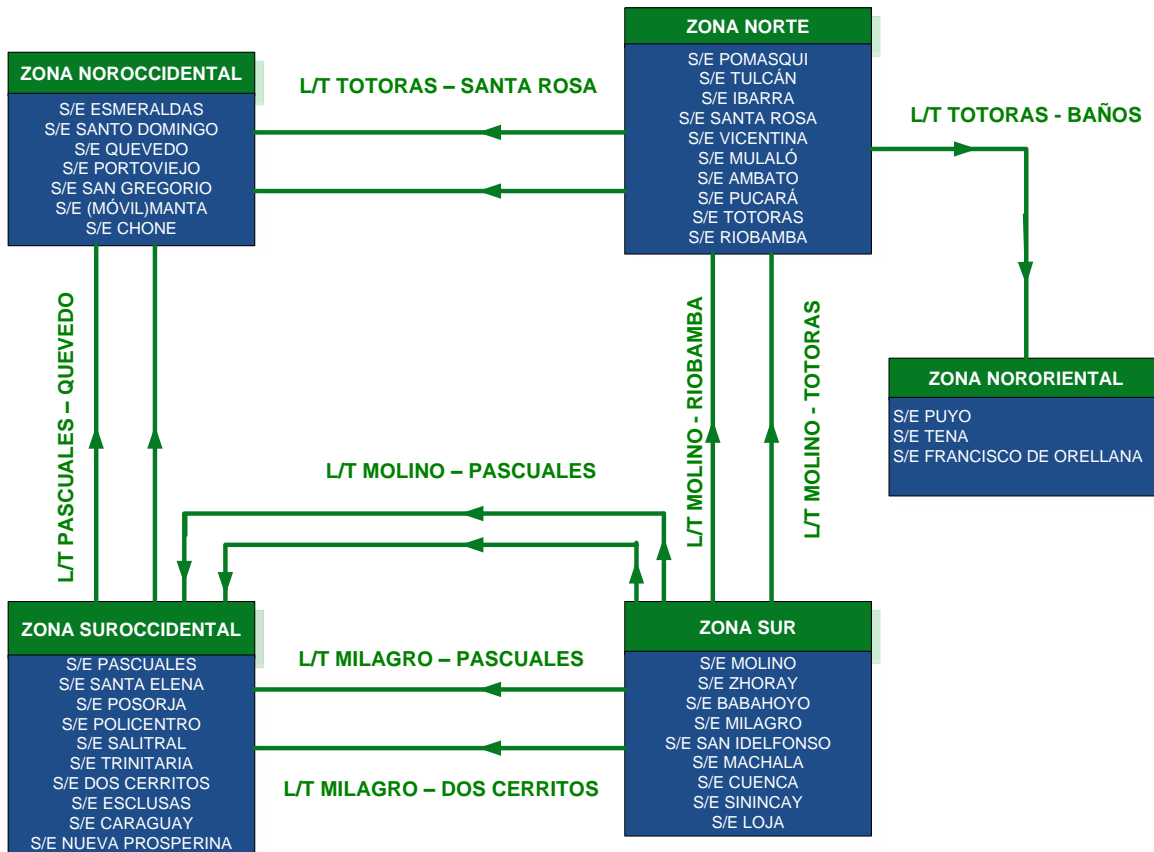


Gráfico 12. Zonas Operativas del Sistema Nacional de Transmisión.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 3, perspectiva y expansión del sistema eléctrico ecuatoriano, capítulo 3 expansión de la transmisión, 3.2 Sistema actual.

El sistema nacional de transmisión se agrupado en cinco zonas operativas: Norte, Nororiental, Noroccidental, Sur y Suroccidental, de acuerdo al esquema organizacional del sistema de transmisión del Gráfico 12. La configuración topológica del sistema es la existente a diciembre 2012, sobre ella se realiza el diagnóstico de las condiciones operativas del SNT en función de su demanda y generación, actuales y futuras.[3]

1.1.2.1 Líneas de Transmisión.

A nivel de 230 kV existen 1.285 km de líneas en doble circuito y 556 km en simple circuito, gran parte de ellas formando un anillo entre las subestaciones Molino, Zhoray, Milagro, Dos Cerritos, Pascuales (Guayaquil), Quevedo, Santo Domingo, Santa Rosa (Quito), Totoras (Ambato) y Riobamba, vinculando de forma directa a los principales centros de generación

con los grandes centros de consumo del país.

A nivel de 138 kV se cuenta con 625 km de líneas en doble circuito y 1.093 km en simple circuito, que fundamentalmente parten de manera radial desde el anillo de 230 kV.

Como parte de las instalaciones en operación del SNT existen además, a nivel de 230 kV, algunas líneas de interconexión internacionales:

- Con Colombia: dos líneas de transmisión doble circuito de 212 km de longitud cada una, que enlazan las subestaciones Pomasqui en el lado ecuatoriano con Jamondino en el lado colombiano y que permiten la transferencia de hasta 500 MW.

- Con Perú: una línea de transmisión de 107 km de longitud, que conecta a las subestaciones Machala en el lado ecuatoriano con Zorritos en el lado peruano y que permite la transferencia de hasta 100 MW⁶.

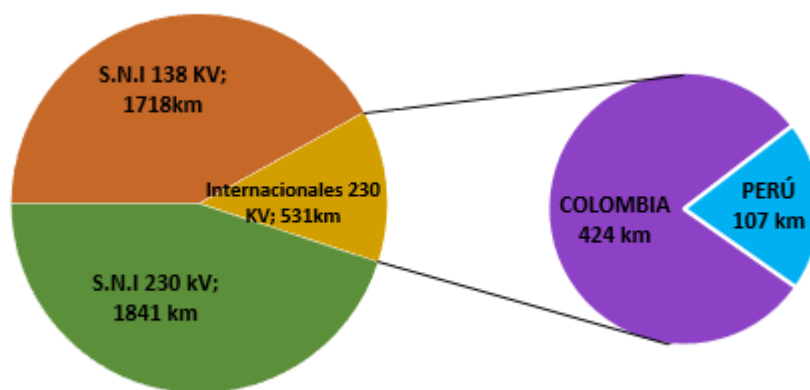


Gráfico 13. Composición de las líneas de transmisión del SNT

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 3, perspectiva y expansión del sistema eléctrico ecuatoriano, capítulo 3 expansión de la transmisión, 3.2 Sistema actual.

En el Gráfico 13 se observa como están compuestas las líneas de transmisión del SNT.

1.1.2.2 Subestaciones.

Respecto a la capacidad de transformación y equipamiento de maniobra, el sistema de transmisión cuenta con 39 subestaciones, las cuales están distribuidas de la siguiente manera:

- 15 subestaciones de transformación de relación 230/138/69 kV.

⁶ PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 3, perspectiva y expansión del sistema eléctrico ecuatoriano, capítulo 3 expansión de la transmisión, 3.2 Sistema Actual, 3.2.1.1 Líneas de transmisión, párrafo 1, 2, 3, 4, 5, pág. 57

- 20 subestaciones de transformación de relación 138/69 kV.
- 2 subestaciones de transformación móviles, una de relación 138/69 kV y otra de relación 69/13,8 kV.
- 2 subestaciones de seccionamiento, una a 230 kV y otra a 138 kV.[3]

La configuración de barras predominante en las subestaciones de 230 kV es la de doble barra principal y a nivel de 138 kV y 69 kV la de barra principal y transferencia; con equipamiento, en su mayoría, de tipo convencional y algunas instalaciones con equipo compacto en SF6.

La capacidad máxima instalada en los transformadores de las subestaciones del SNT es del orden de los 8.521 MVA, de los cuales 917 MVA corresponden a la capacidad de reserva de los transformadores monofásicos en varias subestaciones⁷.

1.1.3 Expansión de la distribución.

Los planes de expansión permitirán a las distribuidoras cumplir con la normativa vigente en lo referente a los niveles de calidad de servicio hacia los consumidores, para lo cual adecuarán progresivamente sus instalaciones, organización, estructura y procedimientos técnicos y comerciales, a fin de llegar a los niveles establecidos considerando los siguientes aspectos

- Aumento de la cobertura eléctrica.
- Mejoramiento de la infraestructura eléctrica.
- Reducción de pérdidas de energía; e
- Incremento de los niveles de calidad del servicio eléctrico.

En la actualidad la prestación del servicio eléctrico se encuentra bajo la responsabilidad de 11 empresas; nueve empresas con régimen de transición de sociedades anónimas a empresas públicas y las dos empresa públicas, Corporación Nacional de Electricidad, CNEL EP, que reúne a diez unidades de negocio y la Empresa Pública Eléctrica de Guayaquil, de acuerdo a lo expuesto en la Tabla 3.

⁷ PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 3, perspectiva y expansión del sistema eléctrico ecuatoriano, capítulo 3 expansión de la transmisión, 3.2 Sistema actual, 3.2.1.2 Subestaciones, párrafo 3 y 4, pág. 58.

DENOMINACIÓN	EMPRESA	PROVINCIAS SERVIDAS	ÁREA DE CONCESIÓN (km ²)
Corporación Nacional de Electricidad CNEL EP	Bolívar	Bolívar	39.997
	El Oro	El Oro, Azuay	6.475
	Esmeraldas	Esmeraldas	15.366
	Guayas - Los Ríos	Guayas, Los Ríos, Manabí, Cotopaxi, Azuay	10.511
	Los Ríos	Los Ríos, Guayas, Bolívar, Cotopaxi	4.059
	Manabí	Manabí	16.865
	Milagro	Guayas, Cañar, Chimborazo	6.175
	Sta. Elena	Guayas, Sta. Elena	6.774
	Sto. Domingo	Sto. Domingo de los Tsáchilas, Esmeraldas	6.574
	Sucumbíos	Sucumbíos, Napo, Orellana	37.842
Empresas Eléctricas		Tungurahua, Pastaza, Morona Santiago, Napo	40.805
	Ambato	Napo	
	Azogues	Cañar	1.187
	Centro Sur	Azuay, Cañar, Morona Santiago	28.962
	Cotopaxi	Cotopaxi	5.556
	Galápagos	Galápagos	7.942
	Norte	Carchi, Imbabura, Pichincha, Sucumbíos	11.979
	Quito	Pichincha, Napo	14.971
	Riobamba	Chimborazo	5.940
	Sur	Loja, Zamora, Morona Santiago	22.721
Pública de Guayaquil EP	Guayas	1.104	

Tabla 3. Empresas de Distribución

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 1 Resumen Ejecutivo, Capítulo 5 Expansión de la distribución.

1.2 Participación del CENACE en la operación del SNI

El CENACE fue creado en la Ley de Régimen de Sector Eléctrico, como una Corporación Civil de derecho privado, sin fines de lucro, cuyos miembros incluyen a todas las empresas de generación, transmisión, distribución y los grandes consumidores.

Sus funciones se relacionan con la coordinación de la operación del Sistema Nacional Interconectado (SNI) y la administración de las transacciones técnicas y financieras del Mercado Eléctrico del Ecuador⁸.

⁸ http://www.cenace.org.ec/index.php?option=com_content&view=article&id=45&Itemid=53

1.2.1 Función global

En la Ley de Régimen del sector eléctrico en el capítulo VI se detalla la función global del Operador de sistema CENACE, la cual de manera general se resume en efectuar la administración de las transacciones técnicas y financieras del Mercado Eléctrico, debiendo resguardar las condiciones de seguridad de operación del Sistema Nacional Interconectado responsabilizándose por el abastecimiento de energía al mercado, al mínimo costo posible, preservando la eficiencia global del sector y creando condiciones de mercado para la comercialización de energía eléctrica por parte de las empresas generadoras, sin ninguna discriminación entre ellas, facilitándoles el acceso al sistema de transmisión.

1.2.2 Funciones Específicas.

La ley de Régimen del sector eléctrico menciona las funciones que le corresponde en especial al Centro Nacional de Control de Energía.

- a) *“Recabar de todos los actores del mercado eléctrico mayorista, sus planes de producción y mantenimiento así como sus pronósticos de la demanda de potencia y energía de corto plazo;*
- b) *Informar del funcionamiento del mercado eléctrico mayorista y suministrar todos los datos que le requieran o que sean necesarios al Consejo Nacional de Electricidad;*
- c) *La coordinación de la operación en tiempo real del Sistema Nacional Interconectado en condiciones de operación normal y de contingencia, ateniéndose a los criterios y normas de seguridad y calidad que determine el Consejo Nacional de Electricidad;*
- d) *Ordenar el despacho de los equipos de generación para atender la demanda al mínimo costo marginal horario de corto plazo de todo el parque de generación;*

- e) *Controlar que la operación de las instalaciones de generación la efectúe cada titular de la explotación, sujetándose estrictamente a su programación;*
- f) *Aportar con los datos que requiera el Director Ejecutivo del CONELEC para penalizar a los generadores, de conformidad a lo señalado en el reglamento respectivo, por el incumplimiento no justificado de las disposiciones de despacho impartidas;*
- g) *Asegurar la transparencia y equidad de las decisiones que adopte;*
- h) *Coordinar los mantenimientos de las instalaciones de generación y transmisión, así como las situaciones de racionamiento en el abastecimiento que se puedan producir;*
- i) *Preparar los programas de operación para los siguientes doce meses, con un detalle de la estrategia de operación de los embalses y la generación esperada mensualmente de cada central”⁹.*

1.3 Planificación del crecimiento de la demanda eléctrica y programación de la operación.

1.3.1 Proyección de la demanda eléctrica.

En la planificación de la expansión de los sistemas eléctricos, la proyección de la demanda eléctrica cumple un papel fundamental, misma que es insumo necesario para la realización de los estudios en las etapas funcionales de generación, transmisión y distribución para de esta manera garantizar el suministro eléctrico a los usuarios finales[2].

La proyección de demanda futura de energía constituye una acción primaria, básica y esencial en el proceso de decisión de las posibles alternativas de inversión sectorial y de desarrollo a nivel país. Asimismo, constituye un insumo para la elaboración de presupuestos, estudios de pérdidas e inversiones y la realización de cálculos tarifarios.¹⁰

⁹ Ley de Régimen del Sector Eléctrico, Art 24

¹⁰ PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y Gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, 4.1 Introducción, párrafo 1, pág.29.

La proyección de demanda eléctrica consiste en pronosticar lo siguiente:

- Número de abonados.
- Facturación de energía por sectores:
 - Residencial
 - Comercial
 - Industrial
 - Alumbrado público y otros
- Demanda de energía y potencia a nivel de distribución (facturación más pérdidas técnicas y no técnicas).
- Demanda de energía y potencia a nivel de puntos de entrega del SNT.
- Demanda de energía y potencia a nivel de bornes de generación (generación bruta).

Para la proyección se consideran tres escenarios correspondientes a la dinámica de crecimiento de los sectores productivos y la población: menor, largo y mayor[2].

La Tabla 4 muestra la expectativa de crecimiento de la demanda en años futuros.

Expectativa Escenario Medio	Meta %
Cobertura nacional a final año 2013	97
Cobertura nacional año 2017	99,74
PIB anual medio, años 2010-2020	4,3

Tabla 4. Expectativa del crecimiento de la demanda eléctrica.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2012 – 2021, Capítulo 4 Demanda Eléctrica, subcapítulo 4.2 Proyección de la demanda eléctrica.

1.3.2. Proyección de la demanda eléctrica sector residencial.

Clientes residenciales.

Como resultado de la proyección del crecimiento del sector residencial se espera que la cantidad de clientes en el futuro mantenga su tendencia creciente pero a un menor ritmo de crecimiento, se espera que en promedio incremente un 3.9% en el periodo 2013-2022 hasta alcanzar los 5.5 millones de clientes al término de este periodo.

Esta desaceleración en el crecimiento se debe principalmente al alto grado de cobertura ya alcanzado (2010: 94,77%), otro factor que influye es la escasa variación prevista en la tasa de crecimiento promedio anual en la población. [3]




Gráfico 14. Evolución histórica y proyección de clientes del sector residencial.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.4.1 Sector residencial.

El Gráfico 14 muestra la evolución histórica del crecimiento de clientes del sector residencial, la proyección futura de clientes en el sector residencial y el porcentaje de crecimiento anual, el porcentaje de crecimiento presenta una desaceleración, esto se debe al alto grado de cobertura ya alcanzado y a la escasa variación la tasa de crecimiento promedio anual de la población.

Consumo residencial.

El consumo residencial total se obtuvo de la suma de las proyecciones de consumo residencial de clientes del FERUM y los clientes residenciales. Como resultado de la proyección se espera que el consumo residencial de los clientes totales crezca a una tasa promedio anual del 4,8% en el período 2013 - 2022, alcanzando 9.004 GWh en el horizonte del estudio¹¹.

¹¹ PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y Gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.4.1 Sector residencial, párrafo 2, pág. 34.




Gráfico 15. Evolución histórica y proyección del consumo del sector residencial.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.4.1 Sector residencial.

1.3.3. Proyección de la demanda eléctrica sector comercial.

En el Gráfico 16 se observa la cantidad de clientes del sector comercial que presenta en general una tendencia creciente a lo largo del período histórico con tasas de crecimiento próximas al 5% a excepción del año 2011 que creció fuertemente al 7,1%. El crecimiento promedio histórico 2000 - 2012 fue del 4,8% y del 5% en el período 2006 - 2012. Como resultado de la proyección se estima un crecimiento promedio anual 2013 - 2022 del 3,5% alcanzando 613.000 clientes comerciales al final del periodo[3].




Gráfico 16. Evolución histórica y proyección de clientes del sector comercial.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.4.2 Sector comercial.

Consumo comercial.

El Gráfico 17 muestra la energía facturada del sector comercial presenta en general una tendencia creciente a lo largo del período histórico con tasas de crecimiento desde el 2004 de alrededor del 7,5% a excepción del 2007 (4,3%) que refleja la desaceleración registrada en la economía nacional. El crecimiento promedio histórico 2001 - 2012 fue del 7,3% y del 7,5% en el período 2008 - 2012. Como resultado de la proyección se estima un crecimiento promedio anual 2013 - 2022 del 5,7% alcanzando 5.415 GWh en el horizonte del estudio[3].




Gráfico 17. Evolución histórica y proyección del consumo del sector comercial.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.4.2 Sector comercial.

1.3.4 Proyección de la demanda eléctrica sector industrial.

Clientes Industriales.

La cantidad de clientes del sector industrial presenta en general una tendencia creciente a lo largo del período histórico con ciertas desaceleraciones y una caída en el año 2009 en que la economía nacional sufrió un estancamiento. El crecimiento promedio histórico 2001 - 2012 fue del 4% y del 3,8% en el período 2008 - 2012.

Como resultado de la proyección se estima un crecimiento promedio anual 2013 - 2022 del 2,9% alcanzando 135.384 clientes industriales en el horizonte del estudio¹².

El Gráfico 18 muestra la evolución histórica del crecimiento de clientes del sector industrial, la proyección futura de clientes del sector industrial y el porcentaje de crecimiento anual, existen algunas desaceleraciones como se observa en el gráfico, además de una caída en el año 2009 debido a un estancamiento en la economía nacional.




Gráfico 18. Evolución histórica y proyección de clientes del sector industrial.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.4.3 Sector Industrial.

Consumo industrial.

La energía facturada del sector industrial presenta en general una tendencia creciente a lo largo del período histórico con tasas de crecimiento variables que van desde una caída en el 2001 (-2,9%) al 6,2% en el 2012. Como resultado de la proyección se estima un crecimiento

¹² PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.4.3 Sector industrial, párrafo 1, pág. 36.

promedio anual 2013 - 2022 del 5,1% alcanzando 10.989 GWh en el horizonte del estudio¹³.




Gráfico 19. Evolución histórica y proyección del consumo del sector industrial.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.4.3 Sector Industrial.

El Gráfico 19 muestra la evolución histórica del consumo, la proyección y el crecimiento de energía eléctrica del sector industrial en el periodo 2003-2022, se observa una tasa de crecimiento altamente variable con ascensos y descensos hasta el año 2012, de ahí en adelante se espera tener una tasa equilibrada para los años siguientes hasta el final del periodo.

1.3.5 Proyección de la demanda eléctrica sector alumbrado público.

Según lo establecido en el Plan Maestro de Electrificación, la evolución histórica del alumbrado público no ha sufrido un cambio cualitativo en la serie en los últimos tres años, por tanto el Plan Maestro de Electrificación decidió mantener constante la cantidad registrada en el último año histórico (211 clientes) hasta el horizonte del estudio.

¹³ PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.4.3 Sector industrial, párrafo 2, pág. 36




Gráfico 20. Evolución histórica y proyección de clientes del sector alumbrado público.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.4.4 Sector alumbrado público.

Consumo de alumbrado público.

La proyección del consumo de energía de alumbrado público para el período 2013 - 2022 se realizó en base al crecimiento previsto para los clientes residenciales totales. El supuesto que hay detrás de este comportamiento, es que al incrementarse la cantidad de usuarios, la red crece y paralelamente se incrementa la cantidad de lámparas del alumbrado público.

El crecimiento promedio histórico 2001 - 2012 de la energía facturada del sector alumbrado público fue del 3,3% y del 3,6% en el período 2008 - 2012. Como resultado de la proyección se estima un crecimiento promedio anual 2013 - 2022 del 2,4% alcanzando 1.077 GWh en el 2022 y en 1.143 GWh en el horizonte del estudio.¹⁴

¹⁴ PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.4.4 Sector Alumbrado público, párrafo 2 y 3, pág. 37




Gráfico 21. Evolución histórica y proyección del consumo del sector alumbrado público.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.4.4 Sector alumbrado público.

1.3.6 Resultados de la demanda nacional.

El Gráfico 22 resume la evolución de la energía entregada en la etapa de distribución de electricidad para su venta por tipo de consumo, como resultado de la proyección se estima un crecimiento promedio anual para el periodo 2013 - 2022 del 5% alcanzando 26.542 GWh en el término del periodo[3].




Gráfico 22. Evolución histórica y proyección de la facturación total de energía por grupo de consumo.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.5 Resultados de la proyección de la demanda nacional.




Gráfico 23. Evolución histórica y proyección de la facturación total de energía en el Ecuador.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.5 Resultados de la proyección de la demanda nacional.

Como se observa en el Gráfico 23 la energía facturada total de Ecuador muestra una tendencia creciente en todo el período de análisis histórico (2001 - 2012), presentando fuertes crecimientos en los últimos cinco años (2008 - 2012).

“Para los próximos años se estima una disminución en la velocidad de crecimiento de la

economía nacional lo cual impacta directamente sobre las proyecciones de las categorías industrial, residencial y comercial donde se empleó al PIB como variable explicativa. Como resultado se estima un crecimiento promedio del 3,7% para el período 2013 - 2022, inferior a la tasa de crecimiento promedio registrada históricamente del 4,7% 2000 – 2012”¹⁵.

En el Gráfico 24 se muestra la composición del mercado de distribución eléctrica del Ecuador en los años 2012 y 2022 reflejando que el sector residencial representa en conjunto con el sector industrial más del 70% de la energía facturada del Ecuador en todo el periodo del estudio[3].



Gráfico 24. Composición del mercado de distribución eléctrica del Ecuador, años 2012 y 2022.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.5 Resultados de la proyección de la demanda nacional.

“En cuanto a los clientes, se espera que la tendencia histórica ascendente se mantenga en el futuro con una evolución más moderada, consecuencia de la disminución en la velocidad de crecimiento prevista en los clientes residenciales, que representan más del 88% de los clientes totales del país”¹⁶.

El Gráfico 25 resume la evolución de la cantidad total de clientes del mercado distribución de electricidad del Ecuador, y desagregada por grupo de consumo, para el período 2001 - 2022. Como resultado de la proyección se estima un crecimiento promedio anual 2013 - 2022 del 3,7% alcanzando 5,8 millones de clientes en el 2022[3].

¹⁵ PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.5 Resultados de la proyección de la demanda nacional, párrafo 4, pág. 39

¹⁶ PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.5 Resultados de la proyección de la demanda nacional, párrafo 6 y 7, pág. 39 .




Gráfico 25. Evolución histórica y proyección de clientes totales y por grupo de consumo del Ecuador.

Fuente: PLAN MAESTRO DE ELECTRIFICACIÓN 2013 – 2022, volumen 2, Estudio y gestión de la demanda eléctrica, capítulo 4 Estudio de proyección de la demanda eléctrica, subcapítulo 4.2.4 Proyección global de la demanda por categorías 4.2.5 Resultados de la proyección de la demanda nacional.

1.3.7 Programación de la operación, Análisis energético.

El Plan de Operación del Sistema Nacional Interconectado –S.N.I., período abril 2013 a marzo 2014, tiene como objetivo principal analizar las reservas energéticas del sistema eléctrico, plantear recomendaciones a ser adoptadas para mitigar o eliminar los riesgos para el normal abastecimiento de electricidad al País, y definir políticas operativas para optimizar la operación del sistema. Según lo establece la Ley del sector eléctrico, al CENACE le corresponde planificar la operación del sistema de mediano y corto plazo, aplicando las regulaciones vigentes¹⁷.

1.3.7.1 Empresas participantes en el sistema eléctrico

En la Tabla 5 se presenta a las empresas generadoras que participan en el mercado eléctrico mayorista, y en el caso de CELEC E.P sus unidades de negocio.

¹⁷ Plan de operación anual del Sistema Nacional Interconectado Abril 2013-Marzo 2014, página 10, párrafo 1

EMPRESAS DE GENERACIÓN	UNIDADES DE NEGOCIO
CELEC E.P	HIDROPAUTE, HIDROAGOYÁN, ELECTROGUAYAS, TERMOESMERALDAS, TERMOPICHINCHA, HIDRONACIÓN, TERMOGAS MACHALA.
ELECTROQUIL	
ELECAUSTRO	
EMAAP-Q	
INTERVISATRADE	
ECOLUZ (HCJB)	
HIDALGO & HIDALGO	
TERMOGUAYAS GENERATION	

Tabla 5. Empresas de distribución de energía eléctrica.

Fuente: CENECE PLAN DE OPERACIÓN DEL SISTEMA NACIONAL INTERCONECTADO ABRIL 2013 – MARZO 2014, 2. Aspectos Generales, 2.1 Empresas participantes en el MEM, 2.1.1 Empresas de Generación – modificaciones del autor.

En la Tabla 6 se muestra las empresas de distribución.

EMPRESAS DE DISTRIBUCIÓN
Regional Norte S.A.
Quito S.A.
Cotopaxi S.A.
Ambato S.A.
Riobamba S.A.
Regional Centro Sur S.A.
Regional Sur S.A.
Azogues C.A.
Eléctrica de Guayaquil
CNEL Corporación Nacional de Electricidad E.P.

Tabla 6. Empresas de distribución de energía eléctrica.

Fuente: CENACE PLAN DE OPERACIÓN DEL SISTEMA NACIONAL INTERCONECTADO ABRIL 2013 – MARZO 2014, 2. Aspectos Generales, 2.1 Empresas participantes en el MEM, 2.1.2 Empresas de Distribución – modificaciones del autor.

La empresa encargada del transporte de la energía eléctrica es CELEC E.P-TRANSELECTRIC.

En la Tabla 7 se presentan las empresas auto generadoras.

EMPRESAS AUTOGENERADORAS
AGIP OIL ECUADOR
AGUA Y GAS SILLUNCHI
ECOLUZ (HCJB) PAPALLACTA
MOLINOS LA UNIÓN
PETROPRODUCCIÓN
EMAAP-Q (RECUPERADORA)
PERLABÍ
OCP
LAFARGE (SELVA ALEGRE)
REPSOL YPF
SOC. AGRIC. E IND. SAN CARLOS
ECUDOS
ECOELECTRIC S.A
ENERMAX (Calope)
HIDROABANICO
HIDROIMBABURA
I.M.MEJÍA (La Calera)
La Internacional (Vindobona)
MANAGENERACION (La Esperanza y Poza Honda)- Fuera de operación
CONSORCIO BLOQUE 7 - 21
UNIDAD BLOQUE 15
ELECTROANDINA
ANDES PETROLEUM COMPANY
FAMIPRODUCT - LASSO
EMPRESAS AUTOGENERADORAS

Tabla 7. Empresas autogeneradoras.

Fuente: CENACE PLAN DE OPERACIÓN DEL SISTEMA NACIONAL INTERCONECTADO ABRIL 2013 – MARZO 2014, 2. Aspectos Generales, 2.1 Empresas participantes en el MEM, 2.1.3 Empresas Autogeneradoras – modificaciones del autor.

1.3.7.2 Incorporación de nuevas instalaciones de generación

CONELLEC ha previsto la incorporación, durante el período abril 2013 y marzo 2014, las siguientes centrales y/o unidades:

	Denominación	Capacidad	Fecha de incorporación
Proyectos hidroeléctricos	Baba 2 unidades	42 MW	abr-13
	Isimanchi	2,25 MW	jun-13
	San José de Tambo	8 MW	nov-13
Central Eólica	Villonaco	16,5 MW	abr-13
Proyectos termoelectricos	Esmeraldas II (fuel oil)	96 MW	feb-14

Tabla 8. Incorporación de proyectos de generación.

Fuente: CENACE PLAN DE OPERACIÓN DEL SISTEMA NACIONAL INTERCONECTADO ABRIL 2013 – MARZO 2014, 2. Aspectos Generales, 2.2 Incorporación de nuevas instalaciones de generación – modificaciones del autor.

1.3.7.3 Previsión de la demanda

Para el período de análisis abril 2013 – marzo 2014, los resultados de la proyección de demandas, en bornes de generador, indican los siguientes índices de crecimiento promedio anual: 5,0% en potencia y 5,5% en energía¹⁸.

La Tabla 9 muestra la tasa de crecimiento promedio anual de generación y potencia para el periodo abril 2013 – marzo 2014.

	VALORES ANUALES		% DE CRECIMIENTO
	S/E ENTREGA	BORNES GENERADOR	BORNES GENERADOR
DEMANDA MÁXIMA (MW)	3 340	3 680	5.0
ENERGIA REQUERIDA PERÍODO (GWh)	20 045	20 886	5.5

Tabla 9. Tasa de crecimiento promedio anual de potencia y energía periodo abril 2013-marzo 2014.

Fuente: CENACE PLAN DE OPERACIÓN DEL SISTEMA NACIONAL INTERCONECTADO ABRIL 2013 – MARZO 2014, 3. Información adicional y criterios aplicados, 3.1 Previsión de la demanda – modificaciones del autor.

El la Tabla 10 se muestra el resumen de la proyección mensual de la demanda de potencia

¹⁸ Plan de operación anual del Sistema Nacional Interconectado Abril 2013-Marzo 2014, página 12.

y energía, en bornes de generador, para el período abril 2013 – marzo 2014, se indica en el siguiente cuadro:

año	2013										2014	
mes	abr	may	jun	jul	ago	sep	oct	nov	dic	ene	feb	mar
MW*	3232	3243	3200	3147	3146	3182	3215	3243	3331	3319	3339	3368
GWh	1,740	1,785	1,709	1,719	1,700	1,673	1,739	1,691	1,785	1,792	1,692	1,860

Tabla 10. Resumen de proyección mensual de potencia y energía en bornes de generador, periodo abril 2013 - marzo 2014.

Fuente: CENACE PLAN DE OPERACIÓN DEL SISTEMA NACIONAL INTERCONECTADO ABRIL 2013 – MARZO 2014, 3. Información adicional y criterios aplicados, 3.1 Previsión de la demanda – modificaciones del autor.

1.3.7.4 Plan de mantenimiento

Con base en las declaraciones de los planes de mantenimiento efectuadas por las empresas Generadoras y CELEC TRANSELECTRIC, CENACE procede a realizar la coordinación de mantenimientos para el período abril 2013 – marzo 2014.

Debido a que se ha disminuido las reservas de potencia a valores inferiores al 10%, la capacidad efectiva del S.N.I. no permite atender en este año ciertos mantenimientos en unidades específicas las cuales se detallan en el documento de referencia.¹⁹.

1.3.7.5 Representación del sistema

La representación de sistema se realiza mediante modelación estocástica de las afluencias a las centrales hidroeléctricas, utilizando el programa SDDP aprobado por el CONELEC, los resultados se presentan en valores promedio para las variables relevantes del sistema.

Las unidades termoeléctricas se representan por su potencia efectiva en bornes de generador, descontadas las reducciones de potencia debidas a la tasa por salidas forzadas y las indisponibilidades por mantenimiento. Los resultados corresponden a la potencia en bornes de generador, es decir, incluyendo el consumo por servicios auxiliares²⁰.

¹⁹ Plan de operación anual del Sistema Nacional Interconectado Abril 2013-Marzo 2014, página 13.

²⁰ Plan de operación anual del Sistema Nacional Interconectado Abril 2013-Marzo 2014, página 13-14.

1.4 Modelos de pronóstico utilizados en la actualidad.

La demanda de energía eléctrica, es un proceso estocástico no estacionario, integrado por múltiples componentes individuales; influenciada además por los factores económicos, demográficos, de geografía, estación del año, clima, día de la semana, y otros efectos aleatorios[2].

Para el pronóstico de demanda de energía eléctrica, en la actualidad, se han propuesto una variedad de modelos, los cuales difieren en su complejidad y estructura funcional de predicción; y por lo que respecta al pronóstico de carga en corto tiempo (STLF), se hace énfasis en dos categorías, que son los modelos estadísticos y los de inteligencia artificial; específicamente empleando redes neuronales artificiales[2].

En los métodos estadísticos, las ecuaciones se obtienen, con la relación entre la carga y los factores que influyen directamente en su variación en el tiempo; mientras que el objetivo de las redes neuronales es imitar el comportamiento de redes neuronales biológicas y de esta manera crear un razonamiento lógico, para asociar un resultado entre las variables de entrada y salida, en base a una recolección histórica de valores o situaciones similares del pasado.

Los métodos estadísticos predicen de forma eficiente la demanda de energía para los días ordinarios de la semana, pero debido a la poca flexibilidad de su estructura el método estadístico pierde exactitud en el pronóstico de días festivos, u otros donde se presentan actividades atípicas, como huelgas paros técnicos de las empresas.

Las redes neuronales artificiales, no requieren la experiencia de un operador experto para aprender, debido que establecen sus propias reglas en base a la relación entrada y salida, esto es especialmente ventajoso en los sistemas con características no lineales, además cuentan con mayor flexibilidad para encontrar la relación entre la carga eléctrica y sus factores relativos, especialmente para los días festivos u otros de características especiales; teniendo

como desventaja, el tiempo de aprendizaje y no siempre garantizan la convergencia a un entrenamiento óptimo.

Uno de los requerimientos de vital importancia para el área de planeamiento del CENACE, es el pronóstico diario de demanda de carga eléctrica del sistema de potencia ecuatoriano, ya que la planificación de distribución de energía eléctrica en el país se basa en el pronóstico de demanda. La previsión de la demanda de energía eléctrica influye directamente en la programación diaria (corto plazo) de los despachos de las unidades, de tal manera que garantice el suministro de la energía.

El objetivo de implementar modelos estadísticos que generen pronósticos de demanda confiables es realizar una planificación óptima que ayude a controlar las eventualidades al máximo y como resultado de esto una operación eficiente, económica y segura del sistema, esto a su vez esto representa un significativo ahorro económico de los recursos en el sector eléctrico ecuatoriano.

El CENACE utiliza ciertas funciones del programa estadístico denominado SPSS para obtener un pronóstico de la serie de tiempo, el programa cuenta con una barra de menú personalizada llamada “Estimación de Demanda” la cual se encuentra estructurada para cada día de la semana, esta barra permite cargar datos del día en estudio y otras opciones permite obtener el pronóstico de la demanda.

CAPÍTULO II

MÉTODOS DE PREDICCIÓN DE DEMANDA

En el presente capítulo se tratará acerca del concepto y clasificación de los métodos de predicción, se abordará también los criterios que se toman en cuenta en el momento de realizar un pronóstico, así como el proceso básico para realizar un pronóstico dentro de un marco conceptual de sistemas de pronóstico, además en este capítulo se enfocará a los métodos de predicción utilizados por el operador del sistema que son: el análisis de series de tiempo y las redes neuronales artificiales.

2.1. Concepto y Clasificación de los métodos de predicción.

2.1.1. Conceptos.

El objetivo de realizar un pronóstico de la demanda eléctrica es conocer que potenciales acontecimientos podrían ocurrir en el futuro y de esta manera reducir al mínimo la incertidumbre. El pronóstico óptimo guiará a la toma de decisiones acertadas.

Pronóstico: Es la previsión calculada del futuro a partir de datos obtenidos del presente y el pasado.

Predicción: Es conocer la respuesta esperada de un sistema, ante la presencia de uno o más valores de la variable independiente. Partiendo de estos conceptos, se deduce que el pronóstico indica lo que sucederá en el futuro en base a lo que sucede en el presente y sucedido en el pasado; y, la predicción permite estimar lo que puede suceder, si se presentan cambios en las variables del proceso.

Por estas razones en este trabajo de tesis se tomará en cuenta para la estimación de demanda eléctrica, los valores de carga de periodos pasados, las variables específicas que pueden ser alteradas son: el día y la hora del día, el mes y si el día es festivo o corresponde a vacaciones y los factores climáticos.

2.1.2. Clasificación de los métodos de pronóstico.

Un método de pronóstico consiste en un procedimiento para estimar un valor o valores futuros, a partir del comportamiento de los datos del presente y del pasado, la consideración de sus rangos de horizonte y sus factores dominantes; por tanto, el identificar los datos que se ajusten a un modelo estadístico particular, permitirá determinar valores óptimos para un pronóstico eficiente.

Conceptualmente los métodos de pronóstico se clasifican en: cualitativos, cuantitativos; y, a su vez estos se subdividen por el horizonte de tiempo de predicción: largo, mediano y corto plazo.

2.1.2.1. Métodos cualitativos.

Los métodos cualitativos se basan en estimaciones y opiniones, no requieren de datos históricos a diferencia de los cuantitativos, ni dependen del área de conocimiento donde serán aplicados, solamente se requiere del juicio personal y la experiencia y/o intuición de quien elabora el pronóstico, debido a que se desarrolla en base a la intuición o a la experiencia de quien lo realiza se requiere de amplios conocimientos de lo que se pronostica. Estos métodos son difíciles de reproducir, por la razón de que el autor no especifica un procedimiento formal que empleo en el pronóstico. Estos métodos son utilizados exclusivamente en situaciones particulares de mediano y corto plazo.

Los métodos cualitativos se clasifican en dos grupos: métodos exploratorios o investigativos y métodos normativos.

Métodos Exploratorios: el punto de partida de este método es el pasado y el presente, y se dirigen hacia el futuro de una manera heurística, analizando todas las posibilidades disponibles.

Métodos Normativos: se inicia determinando las metas y objetivos futuros, luego trabajan hacia atrás, analizando si se puede alcanzar dichas metas sujetas a restricciones, recursos y tecnología disponible.

2.1.2.2.Métodos cuantitativos

Para realizar un pronóstico cuantitativo se deben considerar las tres condiciones siguientes:

- Datos históricos del fenómeno que se pretende predecir.
- La información se pueda organizar y cuantificar de manera numérica.
- Se supone que algunos aspectos de los patrones pasados, se repiten en el futuro.

Los métodos cuantitativos se dividen en dos grupos: métodos intuitivos y métodos formales (basado en la estadística).

Métodos Intuitivos: este método se basa en la experiencia empírica y varían dependiendo de la aplicación, son simples y fáciles de usar, su mayor desventaja es que no son tan precisos como los métodos formales.

Métodos formales o estadísticos: estos modelos se dividen en series de tiempo y métodos de regresión.

2.1.2.3.Métodos estadísticos.

Los métodos estadísticos se basan principalmente en el análisis de tiempo, para la demanda se asume que es una combinación lineal de variables independientes.

Los métodos estadísticos se dividen en cuatro modelos que son:

- a) Regresión lineal.
- b) Suavización exponencial.
- c) Filtro Kalman y estimación de estados.
- d) Modelos econométricos de Box-Jenkins.

2.1.2.4.Métodos basados en inteligencia artificial.

Los modelos basados en inteligencia artificial poseen la habilidad de mejorar la precisión, ya que se considera a la demanda como a una función no lineal. Una ventaja importante es

que no requiere ninguna formulación compleja o correlación cualitativa.

*“a) **Sistemas expertos:** se basan en el conocimiento declarativo (hechos sobre objetos, situaciones) y el conocimiento de control (información sobre el seguimiento de una acción), la cual es usada para predecir usando un razonamiento complejo (inferencias), explorando el conocimiento de los especialistas para el desarrollo de las reglas de inferencia*

*b) **Lógica difusa:** acota un grupo de variables de entrada en una salida usando instrucciones lógicas (if – then). Sus reglas son obtenidas de los datos históricos usando un algoritmo de aprendizaje.*

*c) **Razonamiento Inductivo fuzzy (FIR):** esta metodología combina la modelación cualitativa, la cual determina el grupo de variables de entrada que mejor describen el comportamiento entrada – salida de los datos de entrenamiento mediante la identificación de máscaras de correlación (máscaras óptimas) y la simulación cualitativa que compara los datos de prueba con sus k vecinos más cercanos (k -NN “ k Nearest Neighbors ”) de la base de datos de entrenamiento e interpola entre las salidas previamente observadas.*

Es decir, aprende y analiza los patrones observados de las señales medidas para luego predecir el comportamiento futuro en base a su conocimiento del pasado.

*d) **Redes Neuronales Artificiales (ANN):** son modelos no lineales eficientes que tienen la capacidad de aprender, identificar y aproximar. Entre las principales tenemos:*

- Peceptron multicapa.*
- Red de elementos lineales adaptativos (Madaline).*
- Redes Feedforward.*
- Redes Feedforward con retardos temporales (TLFN).*
- Redes recurrentes (Jordan) ”²¹.*

²¹ Pronóstico de la demanda utilizando inteligencia artificial, Lorena del Pilar Herrera, Quito julio 2007, capítulo 2, subcapítulo 2.3 Métodos de Predicción, subcapítulo 2.3.3, página 22-23, párrafo 1-4.

2.2.Marco conceptual del sistema de pronóstico y sus criterios.

2.2.1. Horizontes del tiempo de pronóstico.

El pronóstico generalmente se caracteriza en tres categorías:

- **Pronóstico de corto plazo:** Este pronóstico tiene una duración de hasta un año pero es generalmente menos de tres meses. Se utiliza para planear la compra, el programar trabajo, niveles de mano de obra, asignaciones del trabajo, y los niveles de la producción.
- **Pronóstico de mediano plazo:** este pronóstico tiene una duración a partir de los tres meses hasta los tres años. Es útil en la planificación de ventas, producción y el presupuesto y en el análisis de algunos planes de operación.
- **Pronóstico de largo plazo:** este pronóstico generalmente tiene una duración de los tres años en adelante, los pronósticos de largo alcance se utilizan en planificación de productos nuevos, los gastos en inversión de capital, localización o extensión de la facilidad, e investigación y desarrollo.

2.2.2. Marco conceptual del sistema de pronóstico

Un sistema de pronóstico cuantitativo consta de dos principales componentes las cuales se ilustran en el Gráfico 26. La primera etapa consiste en la construcción de modelos, un modelo de pronóstico se construye a partir de datos pertinentes e información disponible, en este los datos históricos serán la única fuente de información para el modelo. Cuando se propone un modelo, los parámetros son desconocidos, los cuales pueden ser determinados empleando técnicas existentes y robustas, tales como los mínimos cuadrados, se puede utilizar para determinar dichas constantes. Por último el pronosticador debe comprobar la idoneidad del modelo de filtro, en la mayoría de los casos un primer modelo es solo una aproximación y este puede ser inadecuado por las siguientes razones: podría incluir variables inapropiadas o podría estar mal especificada la relación funcional.

Cuando el modelo no es satisfactorio se debe afinar las especificaciones y realizar un nuevo ciclo de especificaciones, estimación y diagnóstico, de forma interactiva, hasta que se

encuentre un modelo satisfactorio y los resultados deseados sean óptimos o el nivel de error sea menor o igual al esperado.

En la segunda etapa, cuando el modelo ya se encuentra en funcionamiento se realizan verificaciones periódicas para comprobar que el modelo se está actualizando y está funcionando de manera óptima, de no ser así se inicia el ciclo de rediseño del modelo.

Para asegurar que los parámetros y la estabilidad del modelo son válidos durante un periodo de pronóstico, se verifica en base a los resultados obtenidos cuando se presentan valores nuevos, con los cuales se realizan los ajustes requeridos; el sesgo de pronóstico es un factor con el cual se mide la capacidad del pronóstico, el cual se estima con las observaciones más recientes, las mismas que sirven para actualizar al modelo[4].

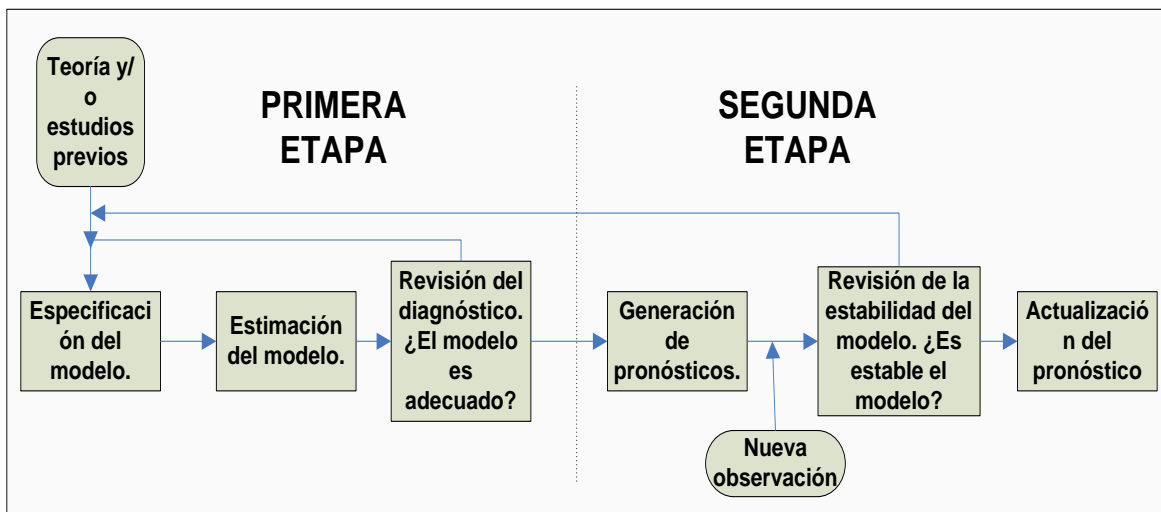


Gráfico 26. Etapas de un sistema de pronóstico

Fuente: Tesis doctoral, Pablo Ortiz Mondragón, México, D.F, 2011, PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO UNA RED NEURONAL ÓPTIMA, capítulo 2. Métodos de Predicción, 2.3 Marco conceptual del sistema de Pronóstico.

2.2.3 Criterios de pronóstico

La precisión es el criterio de mayor importancia al momento de seleccionar un modelo de pronóstico, la precisión refleja la proximidad de los valores pronosticados y el valor reales.

El error de pronóstico se estima comparando la observación Y_t , con el valor estimado \hat{Y}_t ,

planteándose encontrar la función objetivo \widehat{Y}_t , el error de pronóstico se estima con la siguiente ecuación:

$$E = (\widehat{Y}_t - Y_t) \quad (2.1)$$

El objetivo del pronóstico es que el error de pronóstico sea tan pequeño como la necesidad del problema específico lo requiera.

En 1998, Steven C. Wheelwright, Rob J. Hyndman Spyros G. Makridakis, proporcionaron una guía de cinco pasos para el desarrollo de un pronóstico, partiendo de que se cuenta con una cantidad de información para el desarrollo del pronóstico, además a esto la información obtenida se tomará como base y se adaptara al modelo que se proponga[4].

2.2.3.1 Proceso básico para realizar un pronóstico




Gráfico 27. Proceso para el desarrollo de pronóstico.

Fuente: Tesis doctoral, Pablo Ortiz Mondragón, México, D.F, 2011, PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO UNA RED NEURONAL ÓPTIMA, capítulo 2. Métodos de Predicción, 2.4. Criterios de Pronóstico.

Paso 1. Definición del problema

Definir un problema en su totalidad es la parte más compleja para el pronosticador, la dificultad nace desde la definición y limitaciones de los alcances del problema, los requerimientos de para realizar el pronóstico; es importante tener claramente definidos los objetivos del pronóstico y el plazo sobre el que se va a realizar el pronóstico.

Paso 2. Obtención de información

El nivel de precisión de los modelos de pronóstico depende directamente de la veracidad de la información histórica que se dispone, la calidad de la información que se dispone es fundamental, caso contrario el modelo de pronóstico se vuelve vulnerable; la información puede contener errores de diversa índole, debido a que se encuentra almacenada en diversos medios, desde registros en papel, hasta los obtenidos de manera digital por los sistemas de medición.

Paso 3. Análisis preliminar

Para proponer un modelo de pronóstico el primer paso es realizar un análisis preliminar de los datos, este se logra graficando los valores; realizando un análisis estadístico descriptivo (media, desviación estándar, valores máximos, mínimos), descomposición de los datos. Se tiene como objetivo principal descubrir la existencia de patrones, tendencias, estacionalidad, así como también la determinación de valores atípicos evidentes.

Paso 4. Selección y ajuste de los modelos

En esta fase del proceso se propone el modelo de pronóstico que más se ajusta a los valores obtenidos, en esta fase también se reflejan los trabajos desarrollados en la fase anterior.

Para el desarrollo de un pronóstico, existe una gran diversidad de modelos, dependiendo del objetivo por alcanzar en cada caso, por lo que imposibilita que un modelo sea capaz de generalizar sobre cualquier serie de tiempo, más bien cada conjunto de valores puede describirse con un modelo específico.

Paso 5. Utilización y evaluación del modelo de pronóstico

Una vez seleccionado o diseñado el modelo pronóstico y determinado los parámetros, es necesario evaluar su desempeño, esto se realiza antes de poner en operación, el modelo es incompleto si solo permite el ajuste a los valores empleados para su diseño. El desempeño de un modelo de pronóstico solo puede ser evaluado después de haberse probado con un conjunto de valores previamente seleccionados específicamente para este fin. Por esto es importante tener claro el significado de error de ajuste (diferencia que existe entre el modelo teórico y el pronosticado) y error de pronóstico (usado para calcular el límite de confianza del pronóstico), además se debe considerar que en la práctica, los modelos sufren

modificaciones como parte de su proceso natural de perfeccionamiento, de tal manera que cada modelo es solo una propuesta de solución a un problema específico.

2.3 Análisis de series temporales.

Independientemente del modelo de pronóstico que se vaya utilizar, es fundamental conocer el comportamiento de los datos, por esta razón el análisis de la serie de tiempo es una herramienta adecuada para describir el comportamiento de los datos. De acuerdo a los datos que integran una serie de tiempo, esta puede ser continua o discreta[4].

2.3.1. Definición

Serie temporal se conoce al registro metódico de la medición u observación numérica, efectuada a intervalo de tiempos. Para describir lo que es una serie temporal dentro de un contexto de procesos estocásticos, es necesario definir que es un proceso estocástico[5].

“Definición general: Un proceso estocástico es un conjunto de variables aleatorias que dependen de un parámetro o argumento. En el análisis de series temporales el argumento es el tiempo t ”²².

“Definición formal: Un proceso estocástico es una familia de variables aleatorias $\{Y_t\}$, donde t denota el tiempo, tales que para cualquier elección finita de valores de t, t_1, t_2, \dots, t_n existe la distribución de probabilidad conjunta correspondiente a las variables aleatorias $Y_{t_1}, Y_{t_2}, \dots, Y_{t_n}$ ”²³.

2.3.2 Características de las series de tiempo.

La metodología para estudiar las series temporales se basa fundamentalmente en la descomposición de la serie en varias partes.

²² F. O. Ramírez Pérez, *Introducción a las series de tiempo Métodos paramétricos*. 2007, p. 13 párrafo 3

²³ F. O. Ramírez Pérez, *Introducción a las series de tiempo Métodos paramétricos*. 2007, p. 14 párrafo 1

Para realizar un análisis completo y adecuado de una serie de tiempo es necesario graficar todos sus valores, de esta manera es posible detectar irregularidades, valores atípicos en el caso que estén presentes en la serie; las irregularidades que se destacan son la aparición de nivel, cambios periódicos y efectos estacionales.

Para realizar el análisis de datos por intervalos son fundamentales los cambios o discontinuidades que existan dentro de la serie de tiempo.

La manera típica de representar a una serie de tiempo es mediante la suma de sus componentes como se muestra en la siguiente ecuación.

$$Y_t = T_t + S_t + C_t + a_t \quad (2.2)$$

Donde:

Y_t Es un proceso estocástico en este caso se refiere a la demanda de energía eléctrica en un tiempo.

T Tendencia o movimiento a largo plazo.

S Estacionalidad o fluctuaciones de mayor o menor regularidad.

C Ciclo o fluctuaciones irregulares.

a_t Es la componente aleatoria o residual.




Gráfico 28. Serie de tiempo.

Fuente: Autor.

Tendencia: McCleary y Hay, en (1982) definen a la tendencia como: “Cualquier cambio sistemático en el nivel de una serie temporal”²⁴.

Esta componente agrupa el comportamiento de la serie de tiempo en el largo plazo, para poder detectar dicha componente se requiere que la serie conste de una gran cantidad numérica de observaciones de varios años, de tal manera que se pueda apreciar un movimiento creciente, decreciente o estacional. Para el caso en estudio que es la demanda de energía eléctrica, la tendencia se considera en periodos mensuales o anuales y sus movimientos pueden ser lineales o exponenciales esto se relaciona con el crecimiento de los usuarios[6].

En el Gráfico 29 se observa una serie de tiempo con tendencia con sentido positivo (hacia arriba).

²⁴ Análisis de series temporales, Un ejemplo de aplicación en ámbitos psicológicos, María Pilar Jara – Jesús Rosel, pagina 22, párrafo 1




Gráfico 29. Serie Temporal con tendencia.

Fuente: Autor.

Estacionalidad: McCleary y Hay (1982), definen a esta componente como: *“Fluctuaciones cíclicas o periódicas en una serie temporal, que se repite a sí misma en la misma fase de tiempo o período”*²⁵

La estacionalidad son las fluctuaciones que se repiten periodo a periodo con duraciones e intensidades similares, el periodo puede ser diario, semanal, mensual, anual, etc.[6].

*“Cuando un patrón repetitivo es observado sobre un horizonte de tiempo, se dice que la serie tiene un comportamiento estacionario. Los efectos estacionarios están asociados con los cambios en el calendario o climatológicos. Las variaciones estacionales se encuentran atadas a ciclos anuales”*²⁶.

²⁵ Análisis de series temporales, Un ejemplo de aplicación en ámbitos psicológicos, María Pilar Jara – Jesús Rosel, pagina 28, párrafo 3

²⁶ <http://home.ubalt.edu/ntsbarsh/Business-stat/stat-data/Forecasts.htm> Toma de Decisiones con Periodos de Tiempo Crítico en Economía y Finanzas, Profesor Hossein Arsham.

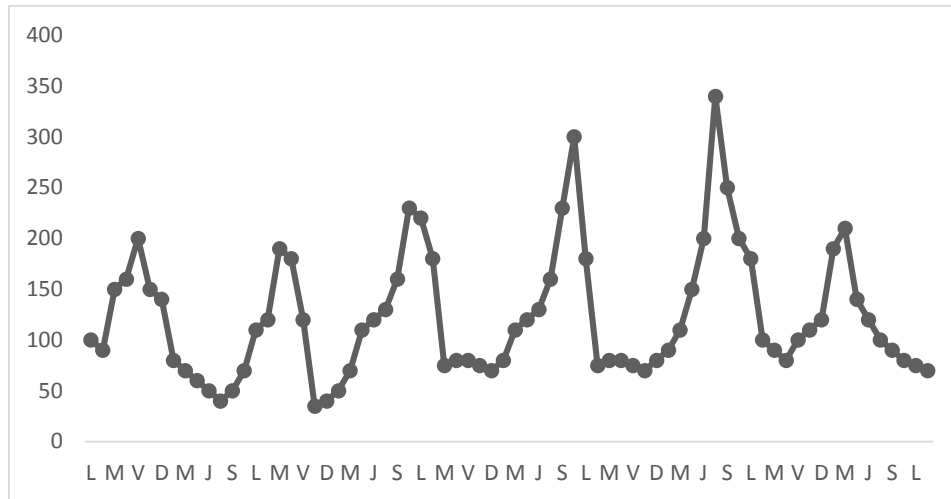


Gráfico 30. Serie temporal con componente estacional semanal

Fuente: Autor.

Ciclicidad: la componente cíclica en una serie temporal se caracteriza por la existencia de cambios u oscilaciones en determinados datos representados por subidas y bajadas que tienden a alejarse del nivel medio de la serie; los cambios que se generan en la serie no dependen de efectos estacionales, ni de tendencias[6].

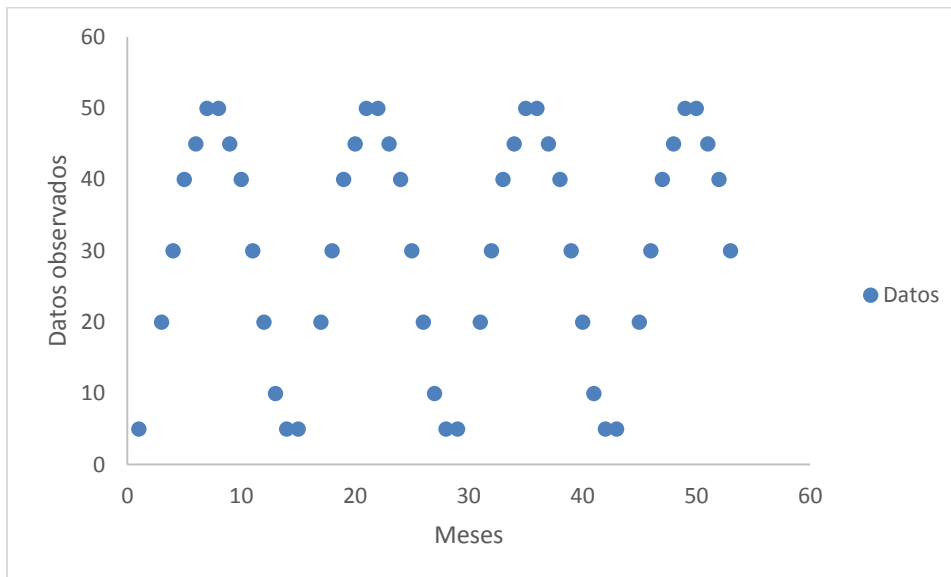


Gráfico 31. Serie temporal mensual cíclica.

Fuente: Autor.

Componente aleatoria: es el cambio que se produce en los valores de una serie de tiempo debido a fenómenos inexplicables, por lo tanto son impredecibles y su ocurrencia cae en el ámbito del azar.

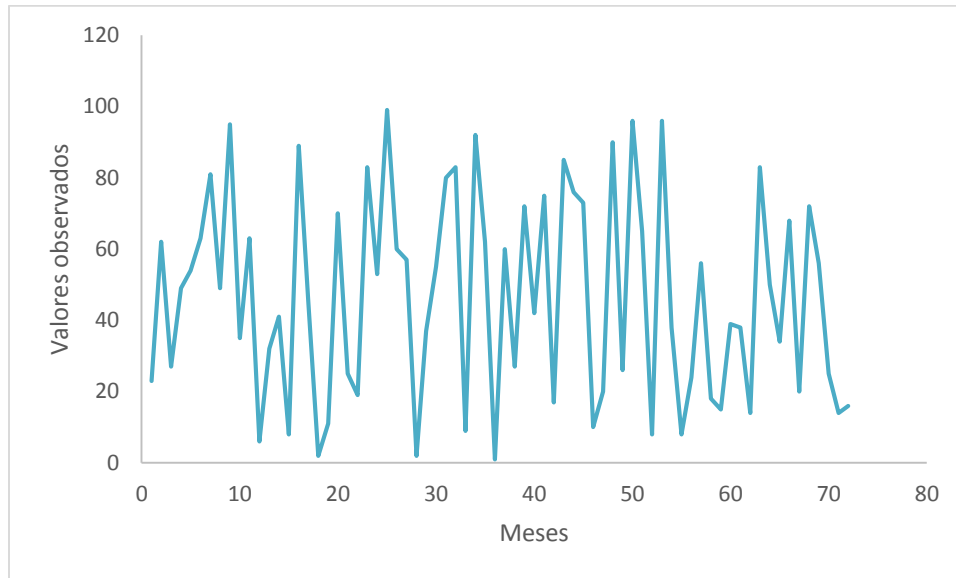


Gráfico 32. Serie temporal con componente aleatoria

Fuente: Autor.

2.4 Redes Neuronales

Para explicar el significado y funcionamiento de las redes neuronales artificiales existe un sin número de definiciones, que van desde breves descripciones, hasta estudios completos, se puede citar un par de ejemplos a continuación:

“Son modelos simplificados de las redes neuronales biológicas. Tratan de extraer las excelentes capacidades del cerebro para resolver ciertos problemas complejos, como: visión, reconocimiento de patrones o control moto-sensorial. Una red neuronal artificial, también llamada neuro – computadora, red conexionista, procesador paralelo distribuido, etc., es un procesador paralelo distribuido y masivamente interconectado que almacena conocimiento experimental.”²⁷.

“Redes neuronales artificiales son redes interconectadas masivamente en paralelo de elementos simples (usualmente adaptativas) y con organización jerárquica, las cuales intentan interactuar con objetos del mundo real del mismo modo que lo hace el sistema

²⁷ E. N. Sánchez Camperos, A.Y. Alanís García, Redes neuronales conceptos fundamentales y aplicaciones a control automático. 2006, capítulo 1 Introduccion a las redes neuronales artificiales, 1.2 Redes neuronales artificiales, p. 5, párrafo 1

biológico”²⁸

De dichas definiciones mencionadas anteriormente se tomaran las principales capacidades de las redes neuronales como son: el aprendizaje mediante entrenamiento, la organización jerárquica e interconexión masiva para resolver el problema de predicción de demanda eléctrica en corto plazo.

Mapas Auto Organizados (SOM): *“Un modelo de mapas auto-organizados (SOM) está compuesto por dos capas de neuronas. La capa de entrada (formada por n neuronas, una por cada variable de entrada) se encarga de recibir y transmitir a la capa de salida la información procedente del exterior. Y la capa de salida (formada por m neuronas) es la encargada de procesar la información y formar el mapa de rasgos”*²⁹.

El trabajo presentado empleará dos arquitecturas principalmente, estas serán empleadas en la metodología propuesta, primero se utilizará la arquitectura de Mapas Auto Organizados (SOM) para clasificar los diferentes patrones de demanda diaria y posteriormente se empleará una arquitectura del tipo conexión hacia adelante (FF) para el desarrollo del pronóstico propiamente.

Una red neuronal de conexión hacia adelante (FF), se caracteriza por su arquitectura en niveles y conexiones estrictamente hacia adelante, esta red se emplea especialmente como clasificador de patrones y emplea un aprendizaje supervisado. A esta clasificación pertenece el modelo del perceptrón, las redes ADALINE, MADALINE y la red de retropropagación; que han la base fundamental y punta de flecha para el desarrollo de otros modelos de ANN[4], mismas que se describen a continuación..

2.4.3 Red de propagación hacia atrás (retropropagación)

“El perceptrón multicapa, inicialmente desarrollado por P. Werbos (1974), posee una estructura con al menos una capa oculta y su algoritmo de entrenamiento es del tipo corrección de error. Se basa en el cálculo del gradiente distribuido en los diferentes

²⁸ James A. Freeman and David M. Skapura, Neural Networks Algorithms, Applications and Programming Techniques. Houston, Texas, USA: Addison-Wesley, 1991.

²⁹ Tesis doctoral, Pablo Ortiz Mondragón, México, D.F, 2011, PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO UNA RED NEURONAL ÓPTIMA, capítulo 2. Métodos de Predicción, 2.8 Redes Neuronales, 2.8.3 Arquitectura de SOM, p. 26, párrafo 3.

*componentes de la red*³⁰.

“Las redes neuronales tipo perceptrón multicapa (MLP, por su nombre en inglés Multilayer perceptron), han sido aplicadas obteniendo resultados positivos en la resolución de diversos y difíciles problemas mediante el algoritmo de retropropagación, este algoritmo consta de dos etapas:

1. Etapa hacia adelante.

Se fijan los parámetros de la red y se aplica un estímulo como señal de entrada a la red, que se propaga hacia adelante para producir una salida.

2. Etapa hacia atrás.

*El error entre la salida deseada y la red se propaga hacia atrás. Los parámetros de la red se modifican para minimizar el cuadro de dicho error*³¹.

Este procedimiento se repite, hasta lograr un mínimo error y/o se alcance un número de específico de iteraciones.

“El MLP tiene tres características que le distinguen:

- 1. El modelo de cada neurona en la red incluye una función de activación no lineal. Lo importante aquí es que la no linealidad es suave es decir que en cualquier punto existen todas las derivadas.*
- 2. La red contiene una o más capas ocultas que no son parte de las entradas o de las salidas de la red. Estas neuronas ocultas permiten que la red aprenda tareas complejas por la extracción progresiva de las características principales de los patrones de entrada.*
- 3. La red presenta altos grados de conectividad, determinados por la sinapsis de la propia red*³².

El acoplamiento de estas características en conjunto con la habilidad de aprender de la experiencia mediante el entrenamiento del MLP da como resultado un gran potencial de computación.

³⁰ E. N. Sánchez Camperos and A. G. A. Yolanda, *Redes neuronales conceptos fundamentales y aplicaciones al control automático*. 2006, capítulo 4, p. 63, párrafo 3.

³¹ E. N. Sánchez Camperos and A. G. A. Yolanda, *Redes neuronales conceptos fundamentales y aplicaciones al control automático*. 2006, capítulo 4, p. 64, párrafo 1 y 2.

³² E. N. Sánchez Camperos and A. G. A. Yolanda, *Redes neuronales conceptos fundamentales y aplicaciones al control automático*. 2006, capítulo 4, p. 64, párrafo 3.

La red de retropropagación tiene la capacidad de autoajustar los pesos de las conexiones de las neuronas de las capas intermedias para aprender la relación entre un conjunto de valores (patrones de entrada) y las correspondientes salidas, de esta forma aplicar estos procedimientos a nuevos valores similares a los ya presentados, o diferentes y estimar una respuesta ante nuevos patrones, lo que se define como capacidad de generalización.

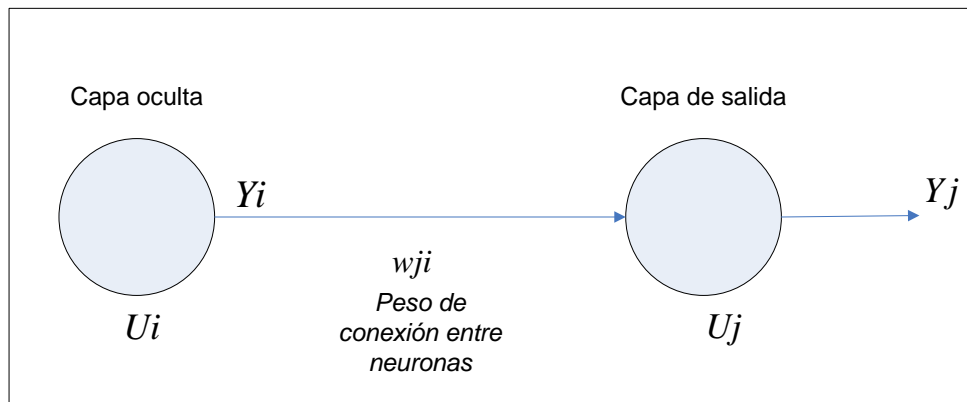


Gráfico 33. Conexión entre una neurona de capa oculta con una neurona de salida

Fuente: Tesis doctoral, Pablo Ortiz Mondragón, México, D.F, 2011, PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO UNA RED NEURONAL ÓPTIMA, capítulo 2. Métodos de Predicción, 2.8. Redes Neuronales, 2.8.1 Red de propagación hacia atrás (retropropagación) – modificaciones de autor.

2.4.2 El algoritmo de retropropagación.

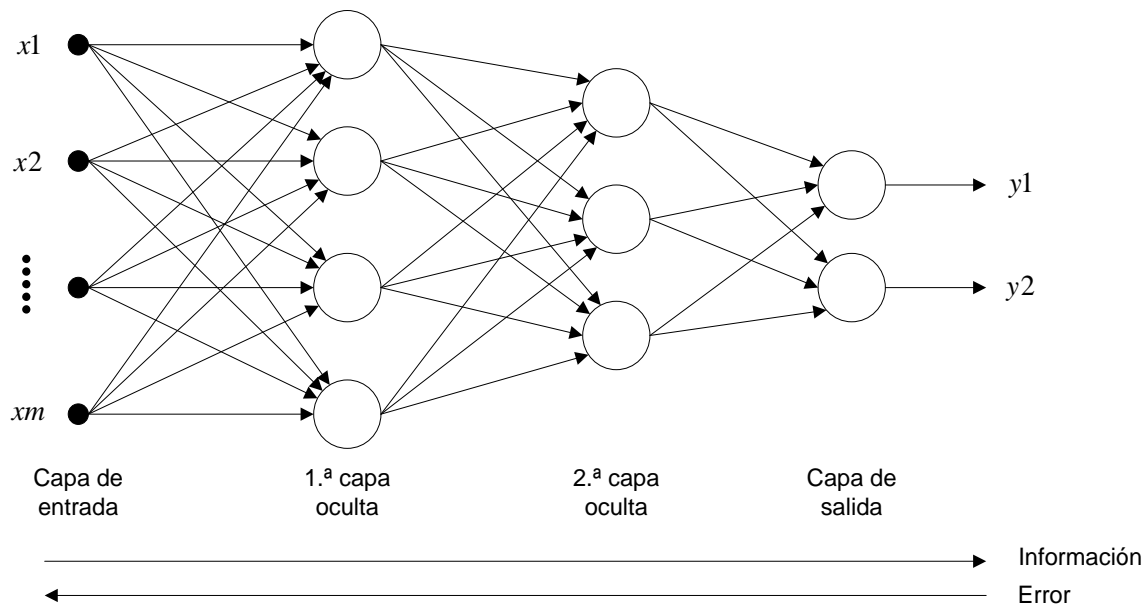


Gráfico 34. Estructura de red neuronal tipo MLP.

Fuente: E. N. Sánchez Camperos and A. G. A. Yolanda, Redes neuronales conceptos fundamentales y aplicaciones al control automático. 2006, capítulo 4 El perceptrón multicapa, 4.1 El algoritmo de retropropagación.

El método que sigue la regla delta generalizada para ajustar los pesos, es el mismo que el empleado por la regla delta en las redes neuronales artificiales del perceptrón, donde los pesos se actualizan de forma proporcional al valor del gradiente, o su vez es la diferencia entre la entrada y la salida[4].

$$\delta = Y_j - \hat{Y}_j \quad (2.3)$$

Si se toma como referencia el Gráfico 33, sea U_j una neurona de entrada, y Y_j la salida que produce, el cambio que se genera en el peso w_{ij} para un patrón de aprendizaje p está definido por la siguiente ecuación:

$$\Delta w_{ij}(t + 1) = \alpha \delta_{jp} y_{pi} \quad (2.4)$$

Donde:

p Representa el patrón de aprendizaje específico.

α Constante o tasa de aprendizaje.

El valor concreto de δ_{jp} punto en el cual difiere la regla delta y la regla delta generalizada. En las redes multicapa, a diferencia de las redes sin neuronas ocultas, no es posible conocer la salida deseada en la capa oculta, de tal forma que sea posible determinar el error cometido, conociéndose solamente la salida de la ANN; por lo anteriormente mencionado, la salida de la neurona U_j se define como [4]:

$$\delta_{pi} = (y_{pi} - \hat{y}_{pi}) \cdot f'(net_j) \quad (2.5)$$

Donde:

y_{pi} Es el valor deseado a la salida de la neurona j para el patrón p

net_j Es la entrada neta a la neurona j .

La ecuación 2.5, es semejante a la regla delta, con la diferencia que se refiere a la derivada

de la función de transferencia. Este término, representa las modificaciones a realizar en la entrada que recibe la neurona j . En caso de que dicha neurona no sea de salida, el error producido, está en función del error que se comete en las neuronas que reciben como entrada, la salida de esta neurona, siendo este el procedimiento de retropropagación del error hacia atrás [4].

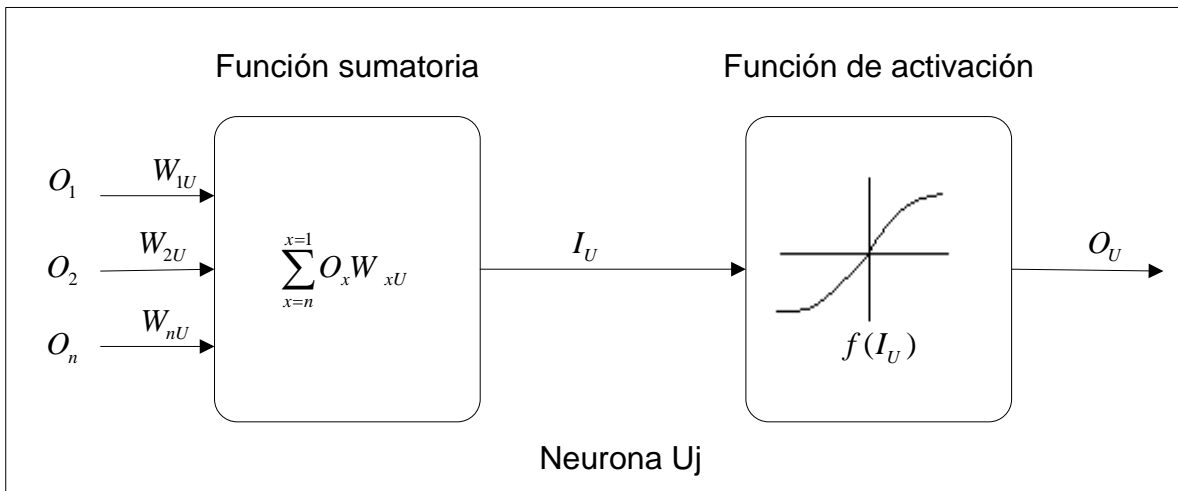


Gráfico 35. Representación de una neurona oculta o de salida.

Fuente: Tesis doctoral, Pablo Ortiz Mondragón, México, D.F, 2011, PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO UNA RED NEURONAL ÓPTIMA, capítulo 2. Métodos de Predicción, 2.8. Redes Neuronales, 2.8.2 Descripción del algoritmo de retropropagación – modificaciones de autor.

En caso que U_j no sea una neurona de salida, el error que se produce, es función del error que se comete en las neuronas que reciben como entrada la salida de la U_j .

$$\delta_{pj} = \left(\sum_k \delta_{pk} w_{kj} \right) \cdot f'(\text{net}_j) \quad (2.6)$$

En la ecuación 2.6, el autor define lo siguiente:

“El rango k cubre todas aquellas neuronas a las que está conectada la salida U_j , así el error que se produce en una neurona oculta, es la suma de los errores que se producen en las neuronas a las que está conectada la salida de ésta última, multiplicando cada una por el peso de la conexión”³³.

³³ Pablo Mondragon, PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO UNA RED NEURONAL. 2011, capítulo 2, p.25, párrafo 4

2.4.3 Optimización de la red neuronal

Existen una gran diversidad de trabajos que tratan acerca de posibles metodologías para el dimensionamiento de la las redes neuronales artificiales (Número de capas y número de neuronas por capa), en la actualidad no existe una regla general para dimensionar una red neuronal artificial, el dimensionamiento queda a criterio e ingenio del diseñador, dependiendo del problema específico que se vaya a resolver se dimensiona a la ANN[4].

Por citar un ejemplo, una ANN con tres capas (entrada, oculta y salida), puede ser lo suficientemente robusta para generalizar la mayoría de problemas no lineales; la posibilidad de agregarle otra capa oculta a la red, en algunas ocasiones puede disminuir el tiempo de aprendizaje de la red. La decisión de cuantas neuronas debe tener la capa oculta también no es evidente ni sigue ninguna regla en general, pues dependerá de la naturaleza de cada problema por resolver[4].

Para lograr eficiencia y exactitud en el procedimiento, se debe ensayar diversas estructuras funcionales, para que de esta manera se pueda seleccionar una que generalice con el menor error, número de neuronas y número de capas óptimas.

2.4.4 Variables de entrada del modelo de pronóstico

La tarea más importante y compleja al momento de diseñar la estructura funcional de ANN, es determinar las variables de entrada del modelo neuronal, y basándose en los estudios y trabajos desarrollados anteriormente, para el pronóstico de la demanda de energía eléctrica, las variables que determinan los valores de la demanda de energía eléctrica son:[4]

- Clima
- Tiempo
- Economía
- Variación aleatoria.

No es una regla general utilizar todas las variables citadas anteriormente, en el pronóstico de demanda eléctrica, debido a que esto puede variar dependiendo la situación geográfica o el alcance del estudio, la selección de estas variables depende de las necesidades del

diseñador.

Clima

La variable para el clima, incluye los valores de temperatura, humedad, velocidad y dirección del viento, nivel de nubosidad, horas luz, cuando el clima llega a valores críticos, cambia las necesidades de los consumidores, como el confort y obliga a utilizar equipos, como son el aire acondicionado o la calefacción por ejemplo, dichos equipos representan un considerable incremento de la demanda³⁴.

La temperatura diaria en las zonas geográficas con climas extremos, es una de las variables más importantes en términos de los efectos sobre la carga eléctrica; de aquí su importancia dentro del STLF[4].

El efecto de la temperatura sobre la demanda de energía eléctrica depende, de la región geográfica del país donde esté ubicada la carga a ser estudiada. En el S.N.I la mayor parte de la demanda eléctrica está distribuida en las región Costa y Sierra de país.

La variable temperatura en este caso tiene efectos contradictorios sobre la demanda total del sistema de potencia en función de las características de cada región por ejemplo: un grado de nubosidad bajo en la Región Interandina o Sierra puede ser asociado con intensos vientos que bajan la temperatura e incrementan la demanda de energía eléctrica del sistema, mientras que en la Región del Litoral o Costa, la misma razón de nubosidad puede estar asociada a un día templado, lo que disminuirá la demanda eléctrica, además a esto no se tiene datos exactos de temperaturas horarias debido a que las mediciones que realiza el INAMHI son tres veces en el día las 7h00, 13h00 y a las 18h00.

Las temperaturas que se obtienen de las mediciones realizadas subestaciones ubicadas alrededor del país no constituyen medidas representativas del comportamiento climático de

³⁴ Pablo Mondragon, PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO UNA RED NEURONAL. 2011, capítulo 2, p. 32, párrafo 1

todas las regiones del país, ya que el Ecuador por su posición geográfica y la diversidad de alturas impuesta por la cordillera de los Andes, presenta una gran variedad de climas y cambios considerables de temperaturas a cortas distancias. [7]

Tiempo

Los factores de que influye la demanda de energía eléctrica, desde el punto de vista tiempo, son:

- Hora del día
- Día de la semana
- Día festivo
- Mes
- Año
- Horario de verano (En caso de tener estaciones climáticas bien marcadas)
- Calendario escolar (Días laborables)
- Vacaciones etc.

Dependiendo del pronóstico que se vaya a desarrollar, el tiempo tiene mayor diversidad de factores, cuyo impacto se refleja con mayor o menor intensidad.

Economía

Primeramente debemos conocer que el sector energético es una rama estratégica de la economía de cualquier país del mundo, dado que los recursos naturales constituyen la base de los tres pilares del desarrollo sostenible que son económico, social y medioambiental, prueba de ello es la importancia que ha dado el Gobierno en su nuevo período de gestión para impulsar la diversificación de la matriz energética en el Ecuador, con grandes proyectos como son: Coca Codo Sinclair, Mazar Dudas, Minas de San Francisco, Quijos, Sopladora, Tohachi Pilatón, Villonaco, etc.[8].

Los pronósticos sirven para los Agentes del mercado que requieren por ejemplo ofertas de compra/venta de energía, unidades de generación que requieren salir a mantenimiento,

manejo de riesgo, entre otras. Entonces los Agentes del mercado requieren pronósticos confiables para que los productores maximicen su beneficio y los consumidores maximicen sus utilidades.[9]

Variaciones aleatorias

Los sistemas de potencia actuales, están integrados por una n-cantidad y n-diversidad de usuarios, aunque no es posible predecir el consumo particular de energía de cada usuario, a medida que se agrupan estos pequeños consumidores, la curva del perfil de la demanda diaria, toma una forma suavizada, y se genera la información suficiente para hacer un análisis estadístico, y con ello la primera estimación de la demanda [4].

Otro punto para analizar en la demanda es donde existen grandes consumidores, generalmente de tipo industrial, que influyen directa y sustancialmente en la demanda, debido a su aleatoriedad sus horarios de operación, generan considerables variaciones en la curva de demanda diaria, estos factores difícilmente se pueden considerar en un modelo de predicción. Los eventos especiales son otra fuente de variación aleatoria, por ejemplo los eventos deportivos o espectáculos públicos, si bien se tiene conocimiento que incrementará la demanda, no se sabe la magnitud de su incremento [4].

CAPÍTULO III

DESARROLLO DE LA APLICACIÓN UTILIZANDO REDES NEURONALES

En el presente capítulo se tratará acerca del análisis estadístico de la demanda eléctrica, así como también se tratará de la detección y tratamiento de los valores atípicos en series tomadas aleatoriamente para el análisis, este análisis de valores atípicos se realizara mediante el método de diagramas de cajas y método de Grubbs, otro punto a tratar en este capítulo es acerca de la medición de los errores de pronóstico, y finalmente se planteara el modelo matemático a utilizar para el pronóstico de demanda a corto plazo en el SNI.

3.1 Análisis de la demanda eléctrica.

El análisis la demanda de energía eléctrica en manera global permite conocer su comportamiento, es un factor importante para proponer un modelo de pronóstico adecuado, de tal forma, es importante el elaborar la estadística de la serie de tiempo formada por la demanda de energía eléctrica horaria, previo al pronóstico.

3.1.1 Análisis estadístico de los datos.

La demanda de energía eléctrica, como cualquier otro proceso estocástico, atiende a una función de distribución de probabilidad, y dependiendo del periodo que se cubre, será el tipo de función de distribución de probabilidad (FDP) de mejor ajuste a los valores. Es común que para el análisis de los valores de la demanda, se considere a la función de distribución normal, lo cual puede conducir a errores de estimación.




Gráfico 36. Función de densidad de probabilidad 18hs. Lunes-Viernes.

Fuente: Autor.

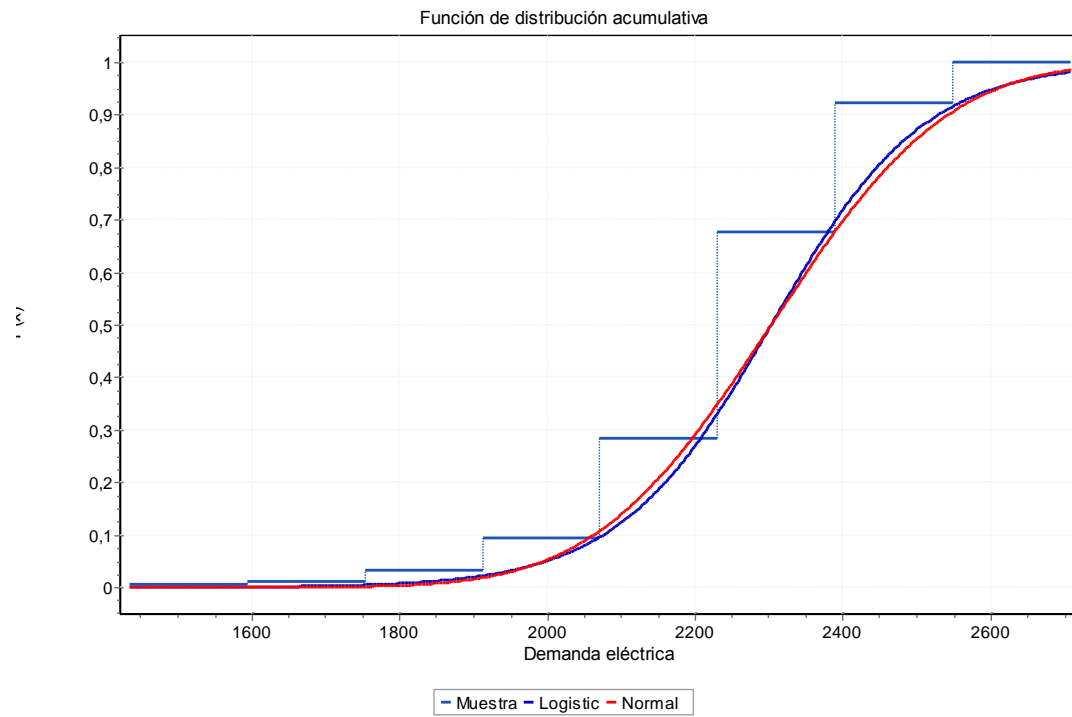


Gráfico 37. Función de distribución acumulativa.

Fuente: Autor.

Como se observa en los Gráfico 36 y Gráfico 37, la función normal, no siempre es la de mejor ajuste para un conjunto de datos, para los datos en estudio de la demanda de energía eléctrica, la función de mejor ajuste, es una función de distribución de Logística (Logistic).

Función de distribución logística: La función de distribución logística se utiliza en el estudio del crecimiento temporal de variables, la función de logística aparece en el contexto de la regresión logística y determinados tipos de redes neuronales. Se parece a la distribución normal en su forma, pero tiene colas más pesadas (y, por lo tanto, mayor curtosis).

La función logística está dada por la siguiente expresión:

$$F(x; \mu, s) = \frac{1}{1+e^{-(x-\mu)/s}} \quad (3.1)$$

Donde:

x Dominio $x \in (-\infty; +\infty)$

μ Ubicación (real)

s Escala (real) $s > 0$

Por lo observado en los gráficos anteriores en un modelo de pronóstico de la demanda de energía eléctrica, es fundamental conocer su comportamiento por lo menos en el periodo sobre el cual se desea hacer el pronóstico, realizar un análisis estadístico de los valores de demanda de energía eléctrica, conduce a conocer profundamente su comportamiento, incrementando la confiabilidad del modelo del sistema de pronóstico.

3.1.2 Función de distribución de probabilidad

Para el análisis estadístico de los datos del presente trabajo de investigación, se propone el empleo de una función de distribución de probabilidad de Logística para la demanda de energía a corto plazo, se llegó a la conclusión de utilizar dicha función de distribución después de realizar la prueba de Kolmogórov-Smirnov la cual indica que la distribución de probabilidad logística es la que brinda mejor bondad de ajuste al modelo de estudio, el empleo de esta distribución de probabilidad permite conocer a profundidad el comportamiento de la demanda.

Prueba de Kolmogórov-Smirnov: En estadística, la prueba de Kolmogórov-Smirnov también conocida como prueba K-S, es una prueba no paramétrica que se utiliza para determinar la bondad de ajuste de dos distribuciones de probabilidad entre sí.

Tomando como ejemplo, la demanda de energía eléctrica de las 18 horas de los días viernes, que se muestra en el Gráfico 36 y Gráfico 37, se tiene que los valores estadísticos para una función normal son $\sigma = 187.67$ y $\mu = 2304.0$.

$$P(X \leq x) = F_x(x) = F_z\left(\frac{x-\mu}{\sigma}\right) = \Phi\left(\frac{x-\mu}{\sigma}\right) \quad (3.1)$$

Siendo Φ un valor que se obtiene de tablas de distribución normal estándar.

Considerando que la distribución normal es simétrica y por lo tanto de acuerdo [10] a la expresión $\mu \pm 2\sigma$ cubre el 95.45% y para $\mu \pm 3\sigma$ cubre el 99.73%, los intervalos de confianza para una distribución normal son:

Mínimo	Máximo	Porcentaje
1928,66	2679,34	95,45%
1740,99	2867,01	99,73%

Tabla 11. Intervalos de confianza.

Fuente: Autor.

Para una función de distribución logística, la probabilidad de ocurrencia en el intervalo de 1905.48 a 2696.32 es del 95.70% con $\mu = 2300.9$, y en el intervalo de 1707.77 a 2894.03, cubre el 99.15%; esto indica que los máximos de la distribución normal ocurren en pocas ocasiones.

3.1.3 Estadísticos principales empleados para el análisis en el pronóstico de demanda eléctrica a corto plazo (STLF).

Los estadísticos empleados para el análisis de la demanda de energía son: El primer momento y segundo momento (media, desviación estándar), auto correlación y la correlación cruzada; de esta manera, es posible determinar la forma en que se encuentran correlacionados los perfiles de demanda de los siete días de la semana, como se muestra en la tabla siguiente, donde se muestra los índices de correlación de la demanda diaria.

	<i>Lunes</i>	<i>Martes</i>	<i>Miércoles</i>	<i>Jueves</i>	<i>Viernes</i>	<i>Sábado</i>	<i>Domingo</i>
Lunes	1						
Martes	0,99751452	1					
Miércoles	0,99752423	0,99831756	1				
Jueves	0,97776842	0,98014921	0,97935588	1			
Viernes	0,99739319	0,99603091	0,99557675	0,98416986	1		
Sábado	0,92738068	0,92644102	0,92478408	0,97604646	0,94409491	1	
Domingo	0,83463471	0,83791478	0,83674352	0,92145455	0,85781805	0,96825057	1

Tabla 12. Matriz de correlación de la demanda diaria de energía eléctrica de la serie de tiempo del periodo 03/01/2012 a 09/01/2012.

Fuente: Autor.

3.2 Identificación de valores atípicos y tratamiento.

El trabajar con datos producto de un proceso de medición o muestreo y de la captura de los mismos, generalmente se producen datos atípicos que pueden ser resultado de errores de captura, o de las operaciones aritméticas de quienes operan con ellos, en estadística a estos valores se les llama atípicos, los cuales son sospechosos de no pertenecer al conjunto de datos donde procede o ser producto de un suceso realmente extraño, dentro de estos pueden encontrarse valores moderados y extremos³⁵.

3.2.1 Fuente de valores atípicos.

Los valores atípicos normalmente provienen de: errores de medición, errores en el registro o captura de los datos, los datos se clasifican en una función de distribución incorrecta, desconocimiento de la estructura de los datos, o fenómenos nuevos. El clasificar un conjunto de datos dentro de una función de distribución incorrecta, tiene como consecuencia el etiquetar valores como atípicos, puesto que los datos que no se ajustan a una función de distribución de probabilidad determinada, pueden ajustarse mejor a otra distribución.

Además el desconocimiento de la estructura y correlación de los datos puede causar aparentes valores atípicos[4].

3.2.1.1 Cuartiles

En estadística existen varios criterios para detectar a los valores atípicos, incluso los mismos paquetes computacionales estadísticos proporcionan rutinas para detectar estos valores, o bien es posible desarrollar procedimientos específicos para detectarlos.

³⁵ Pablo Mondragon, PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO UNA RED NEURONAL. 2011, capítulo 3, 3.2 análisis y tratamiento de datos, p. 38, párrafo 2

Existen diversos criterios para detectar valores atípicos en un conjunto o serie de datos. Uno de los más utilizados es el concepto de cuartil, que consiste en ordenar los datos de menor a mayor, así el primer cuartil, llamado Q_1 , es el valor que se ubica al 25% del conjunto de los datos. El Cuartil segundo Q_2 es el valor a partir del cual se ubica la primera mitad de los datos y es igual al valor de la mediana, así sucesivamente el Q_3 corresponde a los datos que se ubican a la derecha del 75% de los datos[4].

3.2.1.2 Valores atípicos moderados

Valores atípicos moderados se consideran a aquellos mayores o menores a 1.5 veces el rango entre el Q_3 y cuartil Q_1 :

$$L_{inf} = Q_1 - 1.5(Q_3 - Q_1) \quad (3.2)$$

$$L_{sup} = Q_3 + 1.5(Q_3 - Q_1) \quad (3.3)$$

3.2.1.3 Detección de valores atípicos extremos y moderados

Los valores atípicos extremos se pueden detectar aplicando los mismos criterios citados en las ecuaciones 2.8 y 2.9, modificando las ecuaciones como sigue:

$$L_{inf} = Q_1 - 3(Q_3 - Q_1) \quad (3.4)$$

$$L_{sup} = Q_3 + 3(Q_3 - Q_1) \quad (3.5)$$

Los datos que se utilizaran para realizar el análisis de cuartiles, diagrama de cajas y prueba de Grubbs son los que se muestran a continuación:

Día	Fecha	Hora	Demanda
DO.	23/01/2011	14	1799,9
DO.	09/01/2011	14	1801,1
DO.	16/01/2011	14	1852,1
SÁ.	22/01/2011	14	2077,2
SÁ.	08/01/2011	14	2084,1
SÁ.	15/01/2011	14	2140,0
LU.	03/01/2011	14	2154,2
MI.	05/01/2011	14	2239,1
MA.	04/01/2011	14	2270,2
VI.	07/01/2011	14	2276,7
JU.	06/01/2011	14	2295,5
LU.	10/01/2011	14	2308,6
LU.	17/01/2011	14	2325,2
MA.	11/01/2011	14	2327,9
MI.	12/01/2011	14	2363,0
VI.	14/01/2011	14	2363,4

JU.	20/01/2011	14	2365,0
MA.	18/01/2011	14	2377,8
JU.	13/01/2011	14	2414,2
VI.	21/01/2011	14	2433,4
MI.	19/01/2011	14	2445,5

Media	2224,5
Desv. Estándar	199,98814

Tabla 13. Datos que se utilizaran para realizar el análisis de cuartiles, diagrama de cajas y prueba de Grubbs.

Fuente: Autor.

Cuartiles		Rango atípicos moderados		Rango atípicos extremos		Valores muestra	
Q1	2139,98001	<i>Linf</i>	1804,835027	<i>Linf</i>	1469,690046	<i>Linf</i>	1799,9
Q3	2363,41	<i>Lsup</i>	2698,554976	<i>Lsup</i>	3033,699957	<i>Lsup</i>	2445,5

Tabla 14. Límites de rango de valores atípicos moderados y rango de valores atípicos extremos

Fuente: Autor.

3.2.1.4 Diagrama de cajas.

El diagrama de cajas es una herramienta visual para determinar por inspección la existencia de valores atípicos, como se observa en el Gráfico 38, los valores intercuartiles se incluyen dentro de la caja y el 5% y 95 % de confianza se indica con una barra de error hacia afuera de la caja.




Gráfico 38. Diagrama de cajas para las 14 horas del periodo 03/01/2011-23/01/2011

Fuente: Autor.

En la Tabla 14 se muestra los rangos de los valores atípicos moderados y el rango de valores atípicos extremos, como se observa en la Tabla 14 y Gráfico 38 los valores de la muestra no sobrepasan los límites establecidos por las ecuaciones 3.2, 3.3, 3.4 y 3.5, por lo tanto no existen valores atípicos en la serie de datos analizada.

3.2.1.5 Pruebas de Grubbs para la detección de atípicos

Los investigadores proponen diversos métodos para la detección de valores atípicos. Todos los métodos cuantifican que tan lejos están los atípicos del resto de valores, de la media o del valor más próximo al atípico. Posteriormente se divide entre algún valor estandarizado por ejemplo la desviación estándar (S), finalmente se determina la probabilidad “P” que el valor pertenezca a la misma población muestreada.

El método de Grubbs también denominado Desviación T de Student (DTS) es sencillo de comprender y de aplicar. Donde el primer paso es calcular que tan separado está el valor atípico del resto de valores, obteniendo el valor de Z que representa el valor absoluto de la diferencia de la media y el atípico, dividido por la desviación estándar; debe notarse que se calculan los estadísticos de la media (\bar{X}) y la desviación estándar (S), incluyendo el valor atípico.

$$Z = \frac{|\bar{X} - X_i|}{S} \quad (3.6)$$

Demanda	Z
2154,2	0,35149996
2270,2	0,22838445
2239,1	0,07327523
2295,5	0,35504193
2276,7	0,26098638
2084,1	0,70192072
1801,1	2,11700465
2308,6	0,42059582
2327,9	0,51725155
2363,0	0,69246196
2414,2	0,94884382
2363,4	0,69471207
2140,0	0,42250412
1852,1	1,86203953
2325,2	0,50375078
2377,8	0,76676639
2445,5	1,10493644
2365,0	0,70290707
2433,4	1,04448285
2077,2	0,73617276
1799,9	2,12325501




Gráfico 39. Estimación de valores atípicos de una muestra de 21 valores, correspondientes a la demanda de las 14:00 del período 03/01/2011-23/01/2011, con media = 2224,5 y S = 199,98814.

Fuente: Autor.

3.2.1.6 Tratamiento de los valores atípicos

Una vez detectados los valores atípicos, existen dos formas comunes de tratarlos, la primera es eliminarlos de la muestra, esta situación afectará en la estimación; y la segunda es sustituirlos por valores estadísticamente probables, en base a la función de distribución de probabilidad (FDP) de mejor ajuste, siendo aquí donde aplicamos la función logística propuesta como la de mejor bondad de ajuste.

Es común que los datos históricos empleados para realizar estudios contengan errores y estos pueden conducir a resultados erróneos; por lo que se han desarrollado múltiples técnicas para detectar y corregir los problemas con los datos.

3.2.1.7 Medición del error de pronóstico

Estimar la exactitud de un método de pronóstico o también denominado como error de pronóstico, se refiere a conocer la distancia entre el valor real y el estimado; para un solo valor se expresa por la siguiente ecuación:

$$E = Y_t - \hat{Y}_t \quad (3.7)$$

Donde:

Y_t Es el valor observado en el tiempo.

\hat{Y}_t Es el valor estimado para el tiempo t , pero en un tiempo $t-n$, donde n es el horizonte de predicción utilizado.

3.2.1.8 Medidas del error

Los errores de pronóstico, se estiman empleando diferentes métricas, con las cuales se busca la mejor forma de describir la exactitud de un método de pronóstico[4], dentro de estas métricas del error se encuentran las siguientes:

- **Error Medio:** es la distancia dirigida que tiene el dato x_i de la media aritmética muestral o poblacional (promedio). Es decir que tan cercano o lejano está el dato del promedio. Si es positivo indica que el dato x es mayor que la media, si es negativo indica que el dato x es menor que la media. La suma de todos los errores medios es igual a cero, debido a que los valores negativos y positivos se equilibran.

$$ME = \frac{\sum_{i=1}^n E_i}{n} \quad (3.8)$$

- **Error medio absoluto (desviación absoluta media):** es una cantidad que se usa para medir qué tan cerca se encuentran los pronósticos o predicciones de los resultados finales. Como su nombre indica, el error absoluto medio es una media de los errores absolutos, $E = |Y_t - \hat{Y}_t|$ en los que \hat{Y}_t es la predicción y Y_t el valor real. El error absoluto medio es una medida común de error de pronóstico en el análisis de series temporales.

$$MAE = \frac{\sum_{i=1}^n |E_i|}{n} \quad (3.9)$$

- **Error cuadrático medio:** es una de las muchas maneras de cuantificar la diferencia entre los valores implícitos en un estimador y los verdaderos valores de la cantidad que se está estimando. MSE es una función de riesgo, correspondiente al valor

esperado de la pérdida de error al cuadrado o pérdida cuadrática. MSE mide el promedio de los cuadrados de los "errores". El error es la cantidad en que el valor implícito por el estimador difiere de la cantidad a estimar. La diferencia se produce debido a la aleatoriedad o porque el estimador no tiene en cuenta la información que podría producir una estimación más precisa.

$$MSE = \frac{\sum_{i=1}^n E_i^2}{n} \quad (3.10)$$

- **Desviación típica de errores:** también conocido como error estándar de la media (es decir, de la utilización de la media de la muestra como un método de estimación de la media poblacional) es la desviación estándar de la muestra a la media a través de todas las muestras posibles (de un tamaño determinado) extraídas de la población. El error estándar de la media se puede referir a una estimación de que la desviación estándar, calculado a partir de la muestra de datos que están siendo analizados en el momento.

En el análisis de regresión , el término "error estándar" también se utiliza en la frase error estándar de la regresión en el sentido de la ordinaria de mínimos cuadrados estimación de la desviación estándar de los subyacentes errores.

$$SDE = \sqrt{\frac{\sum_{i=1}^n E_i^2}{n-1}} \quad (3.11)$$

- **Error porcentual:** Al calcular los resultados que son el objetivo de los valores conocidos, la fórmula por ciento de error es una herramienta útil para determinar la precisión de sus cálculos. El valor experimental es el valor calculado \hat{Y}_t y el valor teórico es su valor conocido Y_t . Un porcentaje muy cercano a cero significa que está muy cerca de su valor objetivo, lo cual es bueno. Siempre es necesario entender la causa del error, como si es debido a la imprecisión de su equipo, sus propias estimaciones, o un error en el experimento.

$$PE_t = \frac{Y_t - \hat{Y}_t}{Y_t} * 100 \quad (3.12)$$

- **Error porcentual medio:** es la media calculada de los errores porcentuales por que las previsiones de un modelo difieren de los valores reales de la previsión.

$$MPE = \frac{\sum_{i=1}^n PE_i}{n} \quad (3.13)$$

- **Error porcentual absoluto medio:** también conocida como desviación porcentual absoluto medio (MAPE), es una medida de la precisión de un método para calcular los valores de series de tiempo en las estadísticas, específicamente en la estimación de tendencia . Por lo general, se expresa como un porcentaje de precisión.

$$MAPE = \frac{\sum_{i=1}^n |PE_t|}{n} \quad (3.14)$$

En el presente trabajo se utilizara el MAPE y el MAE como indicadores de las medidas de error, se han seleccionado dichas medidas de error por que utilizan los valores absolutos de los resultados obtenidos en sus formulaciones matemáticas, el utilizar los valores absolutos hace que se elimine la compensación entre los valores positivos y negativos como en las otras medidas de error, esto hace que estas medidas de error sean más precisas en sus resultados, además que son las más utilizadas en la estadística en el análisis de series temporales.

En ocasiones el término exactitud, hace referencia a la bondad de ajuste. Una ventaja de la predicción sobre una base de registro histórico de datos, es la posibilidad de estimar la precisión del modelo, empleando como patrón de referencia a un conjunto de valores reservados previamente para tal actividad[10].

En el documento científico [11] se menciona que el MAPE como medida de error de pronóstico no debe exceder el $\pm 5\%$, en el presente trabajo de tesis se tomara dicho criterio como referencia.

3.3 Clasificación de patrones y determinación de variables

Una vez que se tienen una serie de tiempo limpia de valores atípicos, se acondicionan los datos para ser utilizados en el pronóstico propiamente.

3.4 Modelamiento matemático.

3.4.1 Información Utilizada

Para el desarrollo de la investigación, se emplea como información, una serie de tiempo, integrada por el registro de la demanda de energía eléctrica del Sistema Nacional Interconectado, y los valores registrados, pertenecen al consumo horario en Megavatios Hora (MWh), correspondientes al periodo 01 de enero del 2010 a 24 de mayo 2013, obtenida Centro Nacional de Control de Energía CENACE.




Gráfico 40. Serie de tiempo de demanda eléctrica periodo 01-ene-2010 a 31-dic-2010 que se utilizará en el pronóstico de corto plazo.

Fuente: Autor.




Gráfico 41. Serie de tiempo de demanda eléctrica periodo 01-ene-2011 a 31-dic-2011 que se utilizará en el pronóstico de corto plazo.

Fuente: Autor.




Gráfico 42. Serie de tiempo de demanda eléctrica periodo 01-ene-2012 a 31-dic-2012 que se utilizará en el pronóstico de corto plazo.

Fuente: Autor.




Gráfico 43. Serie de tiempo de demanda eléctrica periodo 01-ene-2013 a 24-may-2013 que se utilizará en el pronóstico de corto plazo.

Fuente: Autor.

En el Gráfico 40, Gráfico 41, Gráfico 42 y Gráfico 43 se muestran los valores de la serie de tiempo de la demanda eléctrica, donde se aprecian valores mínimos iguales 1162 MWh y máximos de hasta 3122 MWh, se aprecia la inexistencia valores atípicos en la serie de datos.

3.4.2 Metodología de predicción desarrollada

Como resultado de la bibliografía revisada y los trabajos de experimentación desarrollados durante el presente trabajo de investigación, se propone una metodología con las siguientes cinco fases:

Fase I. Análisis de la demanda de energía eléctrica.

Fase II. Selección de variables de entrada.

Fase III. Dimensionamiento óptimo de la red neuronal.

Fase IV. Entrenamiento de la red y evaluación de resultados.

Fase V. Evaluación del modelo de pronóstico en base al error.

3.4.3 Análisis de perfiles de carga diaria.

Se realiza un análisis de la demanda de energía, graficando los perfiles diarios correspondientes a dos series aleatorias de datos de demanda diaria.




Gráfico 44. Perfil de demanda diaria para el período diciembre 2012-enero 2013.

Fuente: Autor.

En el Gráfico 44 se muestra el perfil de carga diario para dos series de tiempo seleccionadas aleatoriamente, se observa en las curvas que no existen valores que estén fuera de los rangos máximos y mínimos de demanda, además todas las curvas siguen la forma típica del perfil de carga diario, por esto se deduce que no existen valores atípicos en las series seleccionadas para la observación.

3.4.4 Prueba de Grubbs para detectar valores atípicos en los datos de demanda eléctrica del periodo enero 2010 – mayo 2013

Se emplea la expresión 3.6 para calcular los valores de Z para todas las horas del periodo en estudio.




Gráfico 45. Prueba de Grubbs para la detección de valores atípicos.

Fuente: Autor

En el Gráfico 45 el eje de las abscisas representa las horas y en el eje de las ordenadas representa el valor de Z que corresponde al valor de la demanda, se observa en el gráfico que no existen valores de demanda aislados o alejados del conglomerado de datos por lo que se puede concluir que no existen datos atípicos al realizar la prueba de Grubbs.

3.4.5 Diagrama de cajas aplicado en la serie de tiempo de la demanda eléctrica para la detección de valores atípicos.




Gráfico 46. Diagrama de cajas utilizado para la detección de valores atípicos de la serie de tiempo de demanda eléctrica período enero 2010 – 24 de mayo 2013

Fuente: Autor.

En el Gráfico 46 las cruces de color rojo representan a los valores que se encuentren fuera de los límites del diagrama de cajas, no se los consideran como valores atípicos moderados ni extremos debido a que a que los valores no sobrepasan los límites que exponen las expresiones 3.2, 3.3, 3.4 y 3.5 por lo que se puede concluir que no existen valores atípicos en la serie de datos con la que se va a realizar el pronóstico.

El diagrama de cajas y alambres, es similar a la gráfica de perfiles diarios de la demanda, con la diferencia que en la de cajas y alambres se marcan los valores cuando estos están alejados de la mediana, en el caso de estudio se emplea la mediana como dato de referencia, debido a que el diagrama de cajas y bigotes utiliza este criterio, además que la mediana es representa al cuartil segundo donde se ubica la primera mitad de los datos.

3.4.6 Clasificación de patrones




Gráfico 47. Comparación de perfiles de carga para días laborales de la época seca y lluviosa.

Fuente: Autor.

Para los días laborables, se observan patrones de demanda similares para todos los días de la semana, siendo notorio el día lunes de época lluviosa, donde se observa que la demanda inicia muy baja en comparación con los otros días y se empieza a normalizar a las 10:00 de la mañana; este efecto se presenta tanto para la época seca, como para el horario normal.

El análisis de los perfiles de carga diarios, proporcionan información que justifica las variables a considerar en la estructura funcional, como variables de entrada, tal como: la hora del día, el tipo de día y el mes.

3.4.7 Selección de las variables de entrada

Existe una gran dificultad al obtener información de las variables exógenas que afectan a la demanda de energía eléctrica, por ejemplo las del clima que son la temperatura y el punto del rocío, debido a que en el país se realizan muestras solo a tres diferentes horas en el día lo cual no es una información útil debido a que se está trabajando con datos horarios, por este motivo los datos del clima serán adquiridos de páginas web internacionales para completar la series de datos climáticos. Como se citó anteriormente, sobre la dificultad de obtener información precisa sobre variables exógenas que afectan el consumo de energía; sin

embargo es posible considerar a la carga de periodos pasados, como variable de entrada, la cual se considera que ya fue afectada por las diversas variables exógenas, por lo que se consideran sus efectos de forma implícita en la demanda futura, debido a esto se realizaran pruebas de pronósticos utilizando las variables del clima, y pronósticos sin utilizar la variable del clima, posteriormente se realizara un comparación y análisis de la sensibilidad de los pronósticos obtenidos.

Una vez obtenidos los datos de las variables de entrada, se propone un modelo neuronal que tiene como variables de entrada las que se muestran en la Tabla 15.

Variables de tiempo	Día
	Fecha
	Días festivos
	Días laborales
Variables del clima	Temperatura
	Punto de rocío
Variable de la demanda	Demanda histórica

Tabla 15. Variables de entrada a la red neuronal.

Fuente: Autor.

Una vez identificadas las variables de entrada se crea una matriz de predictores para cada caso a estudiar, en el primer caso no se considerara como variables de entrada a la red neuronal las variables del clima para realizar el pronóstico; en el segundo caso las variables del clima si serán consideradas para realizar el pronóstico, dichas matrices de predictores son los datos de entrada para la red neuronal. Las matrices de predictores para los casos correspondientes se muestran en la Tabla 16 y Tabla 17.

Matriz de predictores, datos de entrada a la Red Neuronal, caso 1					
Hora	Día laborable	Día festivo	Demanda horaria de la semana anterior	Demanda horaria del día anterior	Demanda promedio de las 24 horas anteriores

Tabla 16. Matriz de predictores, datos de entrada a la Red Neuronal, caso 1

Fuente: Autor.

Matriz de predictores, datos de entrada a la Red Neuronal, caso 2							
Temperatura	Punto de Rocío	Hora	Día laborable	Día festivo	Demanda horaria de la semana anterior	Demanda horaria del día anterior	Demanda promedio de las 24 horas anteriores

Tabla 17. Matriz de predictores, datos de entrada a la Red Neuronal, caso 2

Fuente: Autor.

3.4.8 Normalización y acondicionamiento

Para facilitar el procesamiento de los datos, dentro del pronóstico, se realiza el escalamiento de los valores, transformándolos a un intervalo de 0-1 esto se conoce como escalamiento en por unidad, para esta tarea, se emplea la expresión siguiente:

$$Y_n = \frac{(Y_{real} + Y_{max})}{2Y_{max}} \quad (3.15)$$

La expresión anterior, no es la única forma de escalar datos, existen otras técnicas de escalamiento, sin embargo se seleccionó el escalamiento en por unidad para tener un mejor manejo de los datos al ejecutar el algoritmo de predicción.

3.4.9 Estructura de la red neuronal.

La herramienta de montaje de red neuronal de Matlab® le ayudará a seleccionar los datos, crear y entrenar a una red, y evaluar su rendimiento mediante el error cuadrático medio y el análisis de regresión.

La red será entrenada con el algoritmo retropropagación de Levenberg –Marquardt, a menos que no hay suficiente memoria, en el que se utilizará el caso escalado retropropagación gradiente conjugado.

Para dimensionar la estructura de la red, sin pérdida de la generalidad y precisión de pronóstico, se desarrolló un programa con análisis en Matlab®, mediante la herramienta de ajuste de red neuronal, para evaluar el desempeño de un cúmulo de redes neuronales variando el número de neuronas de la capa oculta, desde cinco hasta llegar a veinte, obteniendo los resultados que se muestran en la Tabla 18, en donde se puede apreciar las medidas de error de pronóstico MAE y MAPE asociado al número de neuronas de la capa oculta de la red neuronal.

Número de neuronas en la capa oculta	MAE (P.U)	MAPE (%)
5	0,025	3,01833333
6	0,025	3,085
15	0,025	3,03333333
10	0,02666667	3,06666667
11	0,02666667	3,24666667
4	0,02833333	3,18666667
1	0,03166667	3,71666667
8	0,03166667	3,75833333
2	0,035	3,70833333
12	0,03833333	4,62833333
14	0,03833333	4,32666667
18	0,04166667	4,74166667
20	0,04166667	5,24666667
3	0,05	5,53666667
7	0,05	6,055
9	0,69666667	85,87

Tabla 18. Análisis para elegir el número de neuronas en la capa oculta para la red neuronal, caso1 sin incluir la variable del clima como entrada a la red.

Fuente: Autor.

Número de neuronas en la capa oculta	MAE(P.U)	MAPE (%)
2	0,03	3,4
4	0,01433	2,09733334
5	0,015	2,11666667
12	0,02166667	2,69833333

Tabla 19. Análisis para elegir el número de neuronas en la capa oculta para la red neuronal, caso2 incluyendo la variable del clima como entrada a la red.

Fuente: Autor.

En la Tabla 18 y Tabla 19 se muestra el promedio de seis días de las medidas de error (MAE y MAPE), obtenidas al ejecutar el cálculo del pronóstico, el pronóstico fue realizado con diferente número de neuronas capa oculta de la red neuronal.

En la Tabla 18 la red neuronal con cuatro neuronas en su capa oculta, de acuerdo a las medidas de error de pronóstico es la de mejor ajuste, sin embargo la de cuatro neuronas

también proporciona resultados aceptables, la capa oculta con cuatro neuronas es la más eficiente para el entrenamiento por su número de neuronas, debido a que tiene menor número de neuronas en la capa oculta el entrenamiento realiza menor cantidad de interacciones y por consecuencia de esto el tiempo de entrenamiento también disminuye, por lo cual se elige esta estructura para el primer caso de estudio de pronóstico en la presente tesis.

En la Tabla 19 la capa oculta con 4 neuronas es la más eficiente para el entrenamiento por su número de neuronas, por lo cual se elige esta estructura para el segundo caso de estudio de pronóstico en la presente tesis.

Como resultado de la experimentación realizada, se propone emplear una red neuronal de alimentación hacia adelante (FF), con 6 neuronas de entrada, una capa oculta con 4 neuronas, una capa de salida y una neurona de salida, para el caso en el que no se considera la variable del clima, para el segundo caso en el que se consideran las variables del clima como entrada de la red se propone emplear una red neuronal de alimentación hacia adelante (FF), con 8 neuronas de entrada, una capa oculta con 4 neuronas, una capa de salida y una neurona de salida correspondiente a la carga de la hora, de tal forma que la estructuras propuestas son las que se muestra en los gráficos siguientes:




Gráfico 48. Estructura de red neuronal utilizada para el pronóstico de demanda de energía eléctrica en corto plazo en el SNI, sin variables del clima como entrada a la red, Caso1

Fuente: MATLAB R2013a.




Gráfico 49. Estructura de red neuronal utilizada para el pronóstico de demanda de energía eléctrica en corto plazo en el SNI, incluyendo las variables del clima como entrada a la red, Caso2

Fuente: MATLAB R2013a.

Para el aprendizaje de las redes neuronales seleccionadas, se emplearon los parámetros que se muestran en la Tabla 20 y Tabla 21, estos parámetros se utilizan para las 6 series de tiempo que corresponden a los seis días futuros a pronosticar.

Variable	Especificación
Tipo de red neuronal	Perceptrón multicapa
Número de neuronas de entrada	6
Número de capas ocultas	1 con 4 neuronas
Número de iteraciones	372
Ciclo de aprendizaje	1000
Regla de aprendizaje	Levenberg-Marquardt
Número de valores de entrenamiento	18600 (60%)
Número de valores de validación	9300 (30%)
Número de valores de prueba	3100 (10%)
Lenguaje de programación	Script Matlab
Métodos de estimación de error	MAPE, MAE
Tiempo empleado para el entrenamiento	2 minutos y 52 segundos

Tabla 20. Parámetros para el aprendizaje de la red neuronal para el pronóstico de demanda de energía eléctrica en corto plazo en el SNI, sin variables del clima como entrada a la red, Caso1.

Fuente: Autor.

Variable	Especificación
Tipo de red neuronal	Perceptrón multicapa
Número de neuronas de entrada	8
Número de capas ocultas	1 con 4 neuronas
Número de iteraciones	321
Ciclo de aprendizaje	1000
Regla de aprendizaje	Levenberg-Marquardt
Número de valores de entrenamiento	18600 (60%)
Número de valores de validación	9300 (30%)
Número de valores de prueba	3100 (10%)
Lenguaje de programación	Script Matlab

Métodos de estimación de error	MAPE, MAE
Tiempo empleado para el entrenamiento	2 minutos y 54 segundos

Tabla 21. Parámetros para el aprendizaje de la red neuronal para el pronóstico de demanda de energía eléctrica en corto plazo en el SNI, incluyendo las variables del clima como entrada a la red, Caso2.

Fuente: Autor.

Se seleccionó 60% de los datos para el entrenamiento debido a que la red se ajusta en base al error de entrenamiento, se seleccionó el 30% de los datos de validación porque mide la capacidad de generalización de red y para el entrenamiento cuando encuentre la mejor generalización, se seleccionó el 10% de los datos para las pruebas es un porcentaje mínimo ya que es una medida independiente durante y después del entrenamiento de la red además de que no tiene ninguna efecto sobre el entrenamiento de la red.

Para el aprendizaje de la red, se consideró mostrar la evolución del mismo, graficando el error el error cuadrático medio MSE (mean squared error) en relación al número de iteraciones de los datos de aprendizaje, como para los datos de prueba y datos de validación, con lo que es posible hacer un seguimiento de la capacidad de la ANN para generalizar; además de ajustar la relación de aprendizaje durante el proceso de entrenamiento.




Gráfico 50. Proceso de aprendizaje de la red neuronal para el pronóstico de demanda de energía eléctrica en corto plazo en el SNI, sin variables del clima como entrada a la red, Caso1

Fuente: Autor.




Gráfico 51. Proceso de aprendizaje de la red neuronal para el pronóstico de demanda de energía eléctrica en corto plazo en el SNI, incluyendo las variables del clima como entrada a la red, Caso2

Fuente: Autor.

En el Gráfico 50 y Gráfico 51, se muestra el proceso de aprendizaje de las dos redes neuronales, se aprecia el proceso de aprendizaje de los datos de validación, prueba y entrenamiento, mientras el rendimiento de validación sea próximo a cero y el número de iteraciones no tome demasiada tiempo, la red proporciona mejores resultados de pronóstico.

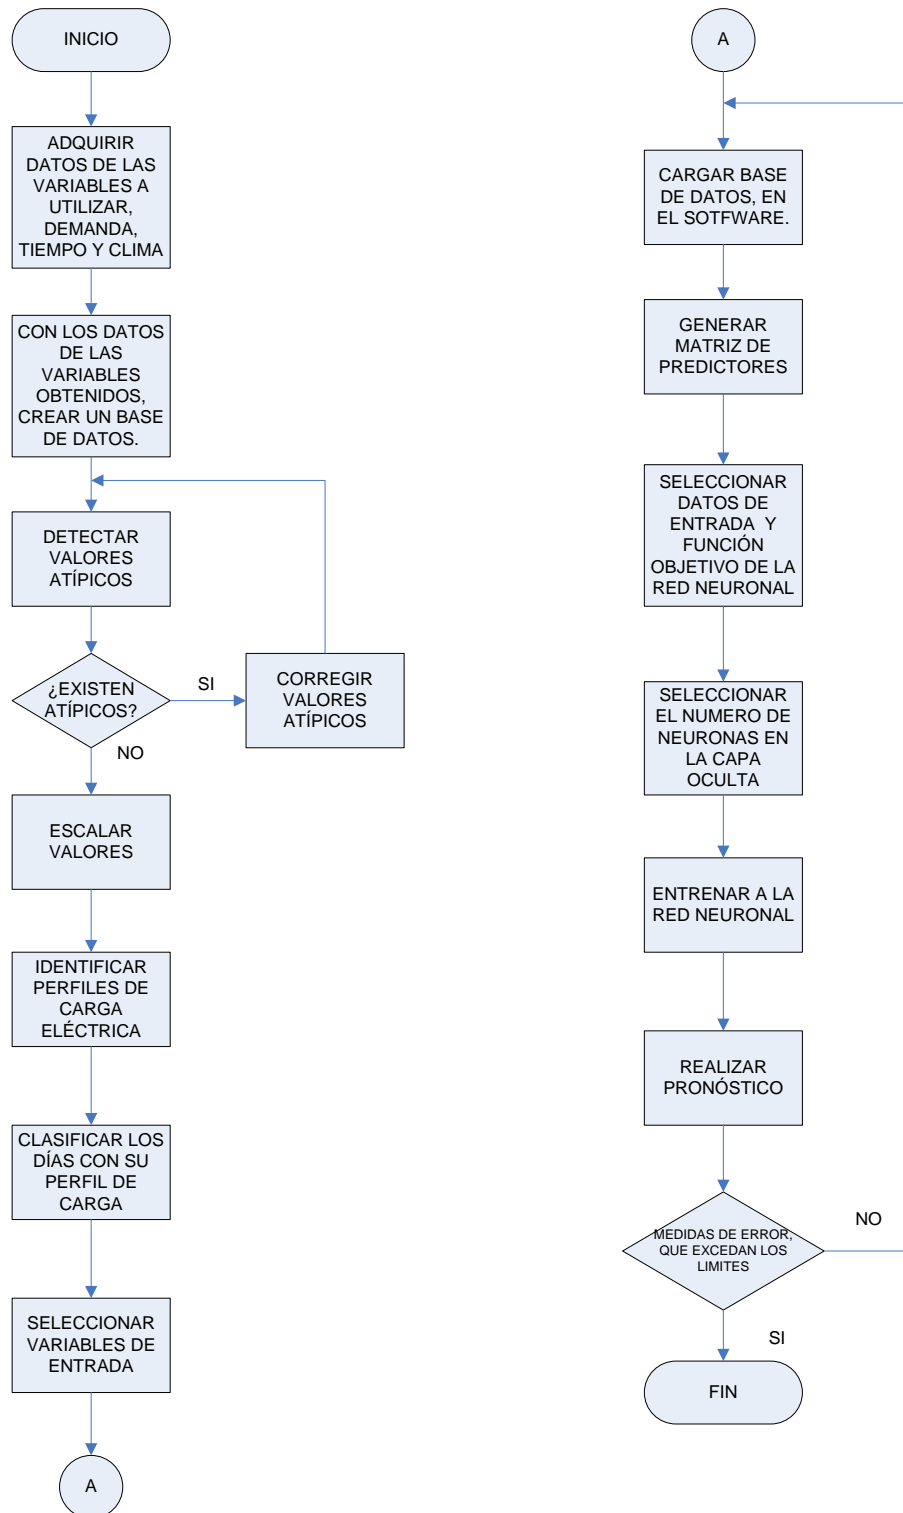



Gráfico 52. Diagrama de la metodología de pronóstico de la demanda de energía eléctrica a corto plazo propuesta.


Fuente: Autor.

3.4.10 Comparación pronóstico Red Neuronal vs Regresión lineal.

Comparación del pronóstico de regresión lineal vs pronóstico de redes neuronales



Comparación del pronóstico de regresión lineal vs pronóstico de redes neuronales






Gráfico 53. Comparación del pronóstico de regresión lineal vs pronóstico de redes neuronales.

Fuente: Autor.

En los gráficos anteriores se exponen las curvas de los pronósticos efectuados con redes neuronales y de las curvas de pronósticos obtenidos de la regresión lineal, dichas curvas fueron seleccionadas de manera aleatoria, se observa que la capacidad de generalización de las redes neuronales es superior en todo momento a la del método de regresión lineal, se puede concluir que el pronóstico de corto plazo con redes neuronales en corto plazo presenta mejores resultados al de métodos convencionales como el de regresión lineal, en la tabla a continuación se muestra un cuadro comparativo de las medidas de error de pronóstico en la que se evidencia que el pronóstico de redes neuronales es superior al pronóstico de regresión lineal.

Comparación de pronósticos regresión lineal vs redes neuronales		
	MAE (P.U)	MAPE (%)
Regresión lineal	0,0106	1,2669
Redes Neuronales	0,0097	1,1658

Tabla 22. Comparación de pronósticos de series de tiempo vs redes neuronales.

Fuente: Autor.

CAPÍTULO IV

ANÁLISIS DE RESULTADOS.

En el presente capítulo se mostraran los resultados obtenidos de la ejecución del pronóstico de demanda eléctrica en corto plazo con redes neuronales, en la primera parte se apreciaran las medidas de error para los dos casos en estudio en esta tesis, se mostrara también gráficos de los valores obtenidos en el pronóstico de la demanda, a continuación de esto se presentará una comparación de los valores obtenidos de la red neuronal con los valores de demanda real proporcionados por el operador del sistema y como parte final se mostrara la factibilidad técnica-económica del desarrollo de la tesis.

4.1 Medición del error de pronóstico.

Empleando los programas del “Anexo3” y “Anexo4”, documentos que muestran los algoritmos desarrollados en Matlab® para entrenar la ANN de retropropagación, y pronosticar la demanda de energía eléctrica de corto plazo, se obtuvieron los siguientes resultados.

FECHA	MAE (P.U)	MAPE (%)
25/05/2013	0.01725	2.0919
26/05/2013	0.02865	3.5482
27/05/2013	0.01293	1.5227
28/05/2013	0.01235	1.45048
29/05/2013	0.01345	1.5015
30/05/2013	0.01401	1.5562

Tabla 23. Medidas de error del pronóstico de demanda de energía eléctrica en corto plazo, caso1.

Fuente: Autor.

FECHA	MAE (P.U)	MAPE (%)
25/05/2013	0.01624	2.0227
26/05/2013	0.03877	4.7579
27/05/2013	0.01584	1.8667
28/05/2013	0.01247	1.4594
29/05/2013	0.01839	2.0561
30/05/2013	0.01783	1.9948

Tabla 24. Medidas de error del pronóstico de demanda de energía eléctrica en corto plazo, caso2.

Fuente: Autor.

En la Tabla 23 y Tabla 24 se muestran los resultados de las medidas del error de pronóstico para los casos 1 y 2 respectivamente, se observa que las medidas de error del pronóstico no exceden el 5% del error en ninguno de los dos casos, por lo que se concluye que se alcanzó el objetivo de no exceder el $\pm 5\%$ en las medidas de error, condición mencionada en el capítulo III, para los días 25-26-27 de mayo del 2013 el MAPE representa el porcentaje excedente que esta sobre el valor de la demanda real lo que indica que el pronóstico permite el abastecimiento del sistema en todo momento, para los días 27-29-30 de mayo del 2013 el MAPE representa el porcentaje que está por debajo del valor de la demanda real es decir que en ciertas horas del día no se logra abastecer al sistema, se presenta esta deficiencia en estos tres días del pronóstico debido a que los datos históricos son de los tres años anteriores, sin embargo los pronósticos de los días 28, 29 y 30 están dentro del rango de error establecido pero sujetos a un ajuste en la base de datos históricos.




Gráfico 54. Diferencia entre el valor de demanda real y demanda pronosticada, caso1.

Fuente: Autor.




Gráfico 55. Diferencia entre el valor de demanda real y demanda pronosticada, caso2

Fuente: Autor.

En el Gráfico 54 y Gráfico 55 se muestran las curvas correspondientes al error que existe entre el valor de la demanda eléctrica real y la demanda eléctrica pronosticada, se aprecia que el error no tiene valores extremos, en las curvas se observa que para ninguno de los dos casos en estudio el error no excede el ± 0.1 .

Para tener una mejor apreciación visual de las curvas de error, se tomó una muestra de las primeras ochocientas horas, las curvas de error de todo el período de análisis (01-01-2010 a 24-05-2013) se presentaran en el “Anexo 5” y “Anexo 6”.

4.2 Resultados de las predicciones utilizando el modelo de redes neuronales.




Gráfico 56. Gráfica comparativa de la demanda real y los valores de pronóstico periodo 01-ene-2010 a 24-may-2013, caso1

Fuente: Autor.

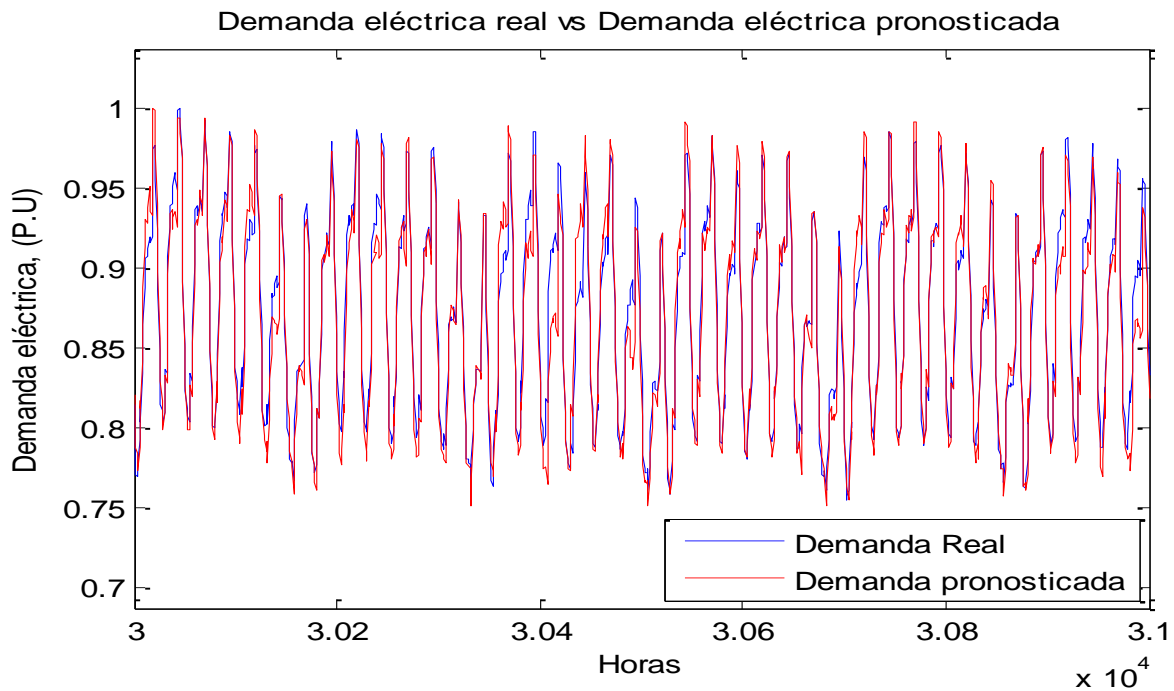


Gráfico 57. Gráfica comparativa de la demanda real y los valores de pronóstico periodo 01-ene-2010 a 24-may-2013, caso2

Fuente: Autor.

En los gráficos anteriores se muestra la curva de demanda eléctrica real vs las curvas de demanda eléctrica pronosticadas, en los cuales se observa el alto grado de precisión, aproximación y generalización de las redes neuronales que presentan los dos casos analizados en la presente tesis.

Para tener una mejor apreciación visual de las curvas de demanda eléctrica real vs las curvas de demanda eléctrica pronosticada, se tomó una muestra de mil horas, las curvas de todo el período de análisis (01-01-2010 a 24-05-2013) se presentaran en el “Anexo 7” y “Anexo 8”.

4.3 Comparación de medidas obtenidas con datos del operador

La base de datos de la demanda histórica diaria que se utilizó en el desarrollo del pronóstico de demanda en corto plazo, se obtuvieron de documentos proveídos por el CENACE, el período empieza el 01-enero-2010 y termina el 24-mayo-2013, debido a esto el horizonte a pronosticar serán los seis días siguientes al 24-mayo-2013, es decir se realizara el pronóstico de demanda los días 25, 26, 27, 28, 29 y 30 de mayo del 2013.

En los gráficos siguientes se muestra la comparación de la demanda real con los datos obtenidos de los pronóstico realizados por las redes neuronales, para los dos casos en estudio, se observa en particular la gran capacidad de generalizar de la red neuronal.




Gráfico 58. Comparación de la demanda real con los valores pronosticados del 25-mayo-2013, caso1

Fuente: Autor.




Gráfico 59. Comparación de la demanda real con los valores pronosticados del 25-mayo-2013, caso2

Fuente: Autor.

FECHA	Caso 1		Caso 2	
	MAE (P.U)	MAPE (%)	MAE (P.U)	MAPE (%)
25/05/2013	0,01725	2,0919	0,01624	2,0227

Tabla 25. Cuadro comparativo de las medidas de error de los pronósticos de demanda en el corto plazo para los dos casos en estudio, respecto a la demanda real, 25-may-2013.

Fuente: Autor.

En la Tabla 25, se muestra un cuadro comparativo de las medidas de error del pronóstico de demanda de corto plazo para los dos casos en estudio, respecto a la demanda real, se observa que el MAPE como medida de error de pronóstico cumple con la condición establecida en el capítulo III de no exceder el $\pm 5\%$, el MAPE en los dos casos presenta valores similares, para esta fecha el incluir los datos del clima como variables de entrada de la red neuronal no garantiza una disminución en el error del pronóstico, por lo que se concluye que los dos casos proporcionan resultados de pronóstico exitosos.




Gráfico 60. Comparación de la demanda real con los valores pronosticados del 26-mayo-2013, caso1

Fuente: Autor.




Gráfico 61. Comparación de la demanda real con los valores pronosticados del 26-mayo-2013, caso2

Fuente: Autor.

FECHA	Caso 1		Caso 2	
	MAE (P.U)	MAPE (%)	MAE (P.U)	MAPE (%)
26/05/2013	0,02865	3,5482	0,03877	4,7579

Tabla 26. Cuadro comparativo de las medidas de error de los pronósticos de demanda en el corto plazo para los dos casos en estudio, respecto a la demanda real, 26-may-2013

Fuente: Autor

En la Tabla 26, se muestra un cuadro comparativo de las medidas de error del pronóstico de demanda de corto plazo para los dos casos en estudio, respecto a la demanda real, se observa que el MAPE como medida de error de pronostico cumple con la condición establecida de no exceder el $\pm 5\%$, se observa que el MAPE en el caso 1 presenta un valor inferior que el caso 2, para esta fecha el incluir los datos del clima como variables de entrada de la red neuronal incrementa en el error del pronóstico, sin embargo ninguno de los dos casos exceden el límite establecido por lo que se concluye que los dos casos en estudio presentan pronósticos exitosos.




Gráfico 62. Comparación de la demanda real con los valores pronosticados del 27-mayo-2013, caso1
Fuente: Autor.




Gráfico 63. Comparación de la demanda real con los valores pronosticados del 27-mayo-2013, caso2
Fuente: Autor.

FECHA	Caso 1		Caso 2	
	MAE (P.U)	MAPE (%)	MAE (P.U)	MAPE (%)
27/05/2013	0,01293	1,5227	0,01584	1,8667

Tabla 27. Cuadro comparativo de las medidas de error de los pronósticos de demanda en el corto plazo para los dos casos en estudio, respecto a la demanda real, 27-may-2013.

Fuente: Autor.

En la Tabla 27, se muestra un cuadro comparativo de las medidas de error del pronóstico de demanda de corto plazo para los dos casos en estudio, respecto a la demanda real, se observa que el MAPE como medida de error de pronóstico cumple con la condición establecida de no exceder el $\pm 5\%$, sin embargo se observa que el MAPE en el caso 1 presenta un valor inferior que el caso 2, para esta fecha el incluir los datos del clima como variables de entrada de la red neuronal incrementa en el error del pronóstico, sin embargo ninguno de los dos casos exceden el límite establecido por lo que se concluye que los dos casos en estudio presentan pronósticos exitosos.




Gráfico 64. Comparación de la demanda real con los valores pronosticados del 28-mayo-2013, caso1.

Fuente: Autor.




Gráfico 65. Comparación de la demanda real con los valores pronosticados del 28-mayo-2013, caso2.

Fuente: Autor.

FECHA	Caso 1		Caso 2	
	MAE (P.U)	MAPE (%)	MAE (P.U)	MAPE (%)
28/05/2013	0,01235	1,4505	0,01247	1,4594

Tabla 28. Cuadro comparativo de las medidas de error de los pronósticos de demanda en el corto plazo para los dos casos en estudio, respecto a la demanda real, 28-may-2013.

Fuente: Autor.

En la Tabla 28, se muestra un cuadro comparativo de las medidas de error del pronóstico de demanda de corto plazo para los dos casos en estudio, respecto a la demanda real, se observa que el MAPE como medida de error de pronostico cumple con la condición establecida de no exceder el $\pm 5\%$, sin embargo ninguno de los dos casos cumple con la condición de abastecer al sistema en todas las horas del día, por lo que se puede concluir que el pronóstico aceptable debido a que se encuentra dentro del límite establecido pero sujeto a un ajuste en la base de datos de demanda histórica para llegar a cumplir la condición de abastecer al sistema.




Gráfico 66. Comparación de la demanda real con los valores pronosticados del 29-mayo-2013, caso1.

Fuente: Autor.




Gráfico 67. Comparación de la demanda real con los valores pronosticados del 29-mayo-2013, caso2.

Fuente: Autor.

FECHA	Caso 1		Caso 2	
	MAE (P.U)	MAPE (%)	MAE (P.U)	MAPE (%)
29/05/2013	0,01345	1,5015	0,01839	2,0561

Tabla 29. Cuadro comparativo de las medidas de error de los pronósticos de demanda en el corto plazo para los dos casos en estudio, respecto a la demanda real, 29-may-2013.

Fuente: Autor.

En la Tabla 29, se muestra un cuadro comparativo de las medidas de error del pronóstico de demanda de corto plazo para los dos casos en estudio, respecto a la demanda real, se observa que el MAPE como medida de error de pronóstico cumple con la condición establecida de no exceder el $\pm 5\%$, se observa que el MAPE en el caso 1 presenta un valor inferior que el caso 2, sin embargo ninguno de los dos casos cumple con la condición de abastecer al sistema en todas las horas del día, por lo que se puede concluir que el pronóstico aceptable debido a que se encuentra dentro del límite establecido pero sujeto a un ajuste en la base de datos de demanda histórica para llegar a cumplir la condición de abastecer al sistema.




Gráfico 68 Comparación de la demanda real con los valores pronosticados del 30-mayo-2013, caso1.

Fuente: Autor.




Gráfico 69. Comparación de la demanda real con los valores pronosticados del 30-mayo-2013, caso2.

Fuente: Autor.

FECHA	Caso 1		Caso 2	
	MAE (P.U)	MAPE (%)	MAE (P.U)	MAPE (%)
30/05/2013	0,01401	1,5562	0,01783	1,9948

Tabla 30. Cuadro comparativo de las medidas de error de los pronósticos de demanda en el corto plazo para los dos casos en estudio, respecto a la demanda real, 30-may-2013.

Fuente: Autor.

En la Tabla 30, se muestra un cuadro comparativo de las medidas de error del pronóstico de demanda de corto plazo para los dos casos en estudio, respecto a la demanda real, se observa que el MAPE como medida de error de pronóstico cumple con la condición establecida de no exceder el $\pm 5\%$, se observa que el MAPE en el caso 1 presenta un valor inferior que el caso 2, sin embargo ninguno de los dos casos cumple con la condición de abastecer al sistema en todas las horas del día, por lo que se puede concluir que el pronóstico aceptable debido a que se encuentra dentro del límite establecido pero sujeto a un ajuste en la base de datos de demanda histórica para llegar a cumplir la condición de abastecer al sistema.

4.4 Factibilidad técnica-económica.

Los valores obtenidos de los pronósticos y de la demanda real se encuentran en una base normalizada en por unidad (P.U) para mejor manejo de los datos como se mencionó en el capítulo anterior. Para realizar un análisis económico, los datos serán convertidos a valores reales es decir a MW, y así poder realizar la evaluación de tipo económico con los datos de demanda real y el predespacho que realiza el CENACE considerando los valores de precio en barra de mercado.

Los datos de demanda de los predespachos así como los precios de los períodos en barra del mercado de demanda se obtuvieron de documentos proveídos por el CENACE (Predespacho económico diario programado), los periodos horarios de la demanda (base, media y punta), se obtuvieron de la codificación del Reglamento de tarifas eléctricas³⁶, dicho documento menciona que:

- Demanda base: 22h00 – 7h00.
- Demanda media: 7h00 – 18h00.
- Demanda punta: 18h00 – 22h00.

Los precios en barra de mercado de los periodos de demanda base, media y punta, son los valores con los se efectuará el análisis económico del proyecto de tesis, se muestran en la siguiente tabla.

PRECIOS EN BARRA DE MERCADO cUSD/kWh 2013-05-25		PRECIOS EN BARRA DE MERCADO cUSD/kWh 2013-05-26		PRECIOS EN BARRA DE MERCADO cUSD/kWh 2013-05-27		PRECIOS EN BARRA DE MERCADO cUSD/kWh 2013-05-28		PRECIOS EN BARRA DE MERCADO cUSD/kWh 2013-05-29		PRECIOS EN BARRA DE MERCADO cUSD/kWh 2013-05-30	
BASE	6,2	BASE	5,3	BASE	5,9	BASE	6,9	BASE	7	BASE	6,2
MEDIA	7,4	MEDIA	5,6	MEDIA	8,1	MEDIA	7,4	MEDIA	8,4	MEDIA	8,6
PUNTA	7,3	PUNTA	6,2	PUNTA	8	PUNTA	6,9	PUNTA	8,5	PUNTA	8,6
DIARIO	7	DIARIO	5,6	DIARIO	7,4	DIARIO	7,1	DIARIO	8	DIARIO	7,8

Tabla 31. Precios en barra de mercado de los periodos de demanda base, media y punta, 25-may-2013 a 30-may-2013.

Fuente: Predespacho económico diario programado, CENACE.

Los valores del cuadro económico comparativo promedio que se muestra en el análisis económico de cada día, se obtienen al realizar el producto del precio de barra en el mercado

³⁶ CODIFICACIÓN DEL REGLAMENTO DE TARIFAS ELÉCTRICAS, Capítulo II Costos, Sección II Metodología de calculos, Art. 8.- Precio Referencial de Generación, literal a. Componente de Energía.

con el promedio de la demanda para cada período de demanda horario base, medio y punta, lo mencionado se expresa en la siguiente ecuación.

$$\text{Costo de demanda(USD)} = \text{Precio de barra en el mercado} \left(\frac{\text{cUSD}}{\text{kWh}} \right) * \text{Promedio de demanda del período horario(Kwh)} \quad (4.1)$$




Gráfico 70. Demanda Real vs Resultados de los pronósticos y predespacho, 25 de mayo 2013. Gráfico

Fuente: Autor.

Cuadro comparativo de las medidas de error 2013-05-25		
	MAE(P.U)	MAPE(%)
Predespacho vs Demanda Real	0,0193968	2,37467
R. Neuronal con variable del clima vs Demanda Real	0,0162451	2,00272
R. Neuronal sin variable del clima vs Demanda Real	0,0172523	2,09197

Tabla 32. Cuadro comparativo de las medidas de error de pronóstico 2013-05-25.

Fuente: Autor.

Cuadro comparativo económico promedio 25 de mayo 2013				
	Demanda Real (USD)	Predespacho (USD)	R. Neuronal sin incluir la variable del clima (USD)	R. Neuronal incluyendo la variable del clima (USD)
Demanda Base	111.348,68	120.350,68	117.062,49	118.539,51
Demanda Media	153.463,31	160.465,28	163.081,94	162.021,44
Demanda Punta	187.768,90	197.482,33	193.981,03	189.621,40

Tabla 33. Cuadro comparativo económico 2013-05-25.

Fuente: Autor.




Gráfico 71. Demanda Real vs Resultados de los pronósticos y predespacho, 26 de mayo 2013.

Fuente: Autor.

Cuadro comparativo de las medidas de error 2013-05-26		
	MAE(P.U)	MAPE(%)
Predespacho vs Demanda Real	0,0174169	2,12565
R. Neuronal con variable del clima vs Demanda Real	0,0387741	4,75792
R. Neuronal sin variable del clima vs Demanda Real	0,0286563	3,54827

Tabla 34. Cuadro comparativo de las medidas de error de pronóstico 2013-05-26.

Fuente: Autor.

Cuadro comparativo económico promedio 26 de mayo 2013				
	Demanda Real (USD)	Predespacho (USD)	R. Neuronal sin incluir la variable del clima (USD)	R. Neuronal incluyendo la variable del clima (USD)
Demanda Base	93.507,48	97.459,73	99.890,23	104.562,48
Demanda Media	104.563,35	111.497,81	118.589,30	119.357,92
Demanda Punta	156.109,60	165.478,28	163.887,40	172.285,68

Tabla 35. Cuadro comparativo económico 2013-05-26.

Fuente: Autor.




Gráfico 72. Demanda Real vs Resultados de los pronósticos y predespacho, 27 de mayo 2013.

Fuente: Autor.

Cuadro comparativo de las medidas de error 2013-05-27		
	MAE(P.U)	MAPE(%)
Predespacho vs Demanda Real	0,0173578	1,96653
R. Neuronal con variable del clima vs Demanda Real	0,0158427	1,86674
R. Neuronal sin variable del clima vs Demanda Real	0,0129322	1,552272

Tabla 36. Cuadro comparativo de las medidas de error de pronóstico 2013-05-27.

Fuente: Autor.

Cuadro comparativo económico promedio 27 de mayo 2013				
	Demanda Real (USD)	Predespacho (USD)	R. Neuronal sin incluir la variable del clima (USD)	R. Neuronal incluyendo la variable del clima (USD)
Demanda Base	109.638,49	113.876,51	114.099,42	117.238,50
Demanda Media	198.025,89	208.526,09	204.923,71	205.795,82
Demanda Punta	231.635,12	242.802,59	234.646,76	233.995,83

Tabla 37. Cuadro comparativo económico 2013-05-27.

Fuente: Autor.

En los gráficos presentados anteriormente se muestra una comparación de los perfiles de demanda reales, predespachos de demanda realizado por el CENACE y los perfiles de demanda obtenidos por las redes neuronales, para los días 25, 26 y 27 de mayo del 2013, se observa que las curvas de los perfiles de demanda obtenidas mediante las redes neuronales siguen la tendencia de la curva de demanda real y abastecen al sistema en todas las horas del día; para realizar el análisis técnico-económico se presentan cuadros comparativos al pie de

los gráficos de perfil de demanda, se observa que el MAPE de los pronósticos obtenidos de las redes neuronales de los días 25 y 27 de mayo del 2013 son inferiores al MAPE del predespacho, en el día 26 de mayo del 2013 se observa que el MAPE del predespacho es inferior al MAPE de los pronósticos de las redes neuronales; el MAPE de los tres días en análisis cumplen con la condición de no exceder el $\pm 5\%$ establecido.

A continuación del cuadro comparativo de las medidas de error , se presenta un cuadro económico comparativo del valor en dólares que cuesta abastecer al sistema en cada una de los periodos horarios (base, media y punta), la comparación se realiza entre el predespacho que realiza el CENACE, los pronósticos obtenidos mediante las redes neuronales en los dos casos de estudio, y el costo de abastecer la demanda real, se observa que el costo de abastecer al sistema en el caso de los pronósticos de las redes neuronales y el predespacho se relaciona directamente con las medidas de error de pronóstico, debido a que si el MAE y el MAPE están cercanos a cero el costo de abastecer al sistema será semejante al costo real, de los resultados obtenidos del análisis se concluye que los pronósticos obtenidos de las redes neuronales son exitosos.




Gráfico 73. Demanda Real vs Resultados de los pronósticos y predespacho, 28 de mayo 2013.

Fuente: Autor.

Cuadro comparativo de las medidas de error 2013-05-28		
	MAE(P.U)	MAPE(%)
Preespacho vs Demanda Real	0,00990966	1,16392
R. Neuronal con variable del clima vs Demanda Real	0,0124673	1,45937
R. Neuronal sin variable del clima vs Demanda Real	0,0123499	1,45048

Tabla 38. Cuadro comparativo de las medidas de error de pronóstico 2013-05-28.

Fuente: Autor.

Cuadro económico comparativo promedio 28 de mayo 2013				
	Demanda Real (USD)	Preespacho (USD)	R. Neuronal sin incluir la variable del clima (USD)	R. Neuronal incluyendo la variable del clima (USD)
Demanda Base	137.837,78	142.184,54	144.658,98	145.513,85
Demanda Media	186.182,71	190.168,64	183.359,83	183.092,51
Demanda Punta	203.318,40	206.055,03	198.715,49	198.791,23

Tabla 39. Cuadro comparativo económico 2013-05-28.

Fuente: Autor.




Gráfico 74. Demanda Real vs Resultados de los pronósticos y preespacho, 29 de mayo 2013.

Fuente: Autor.

Cuadro comparativo de las medidas de error 2013-05-29		
	MAE(P.U)	MAPE(%)
Preespacho vs Demanda Real	0,00730371	0,829861
R. Neuronal con variable del clima vs Demanda Real	0,018387	2,05613
R. Neuronal sin variable del clima vs Demanda Real	0,0134504	1,50149

Tabla 40. Cuadro comparativo de las medidas de error de pronóstico 2013-05-29.

Fuente: Autor.

Cuadro comparativo económico promedio 29 de mayo 2013				
	Demanda Real (USD)	Predespacho (USD)	R. Neuronal sin incluir la variable del clima (USD)	R. Neuronal incluyendo la variable del clima (USD)
Demanda Base	139.825,40	142.758,92	141.674,90	143.276,26
Demanda Media	212.754,85	216.346,53	203.462,00	199.263,67
Demanda Punta	247.947,11	253.172,57	239.521,58	240.477,22

Tabla 41. Cuadro comparativo económico 2013-05-29.

Fuente: Autor.




Gráfico 75. Demanda Real vs Resultados de los pronósticos y predespacho, 30 de mayo 2013.

Fuente: Autor.

Cuadro comparativo de las medidas de error 2013-05-30		
	MAE(P.U)	MAPE(%)
Predespacho vs Demanda Real	0,0180261	2,02281
R. Neuronal con variable del clima vs Demanda Real	0,0178303	1,99423
R. Neuronal sin variable del clima vs Demanda Real	0,0140068	1,55623

Tabla 42. Cuadro comparativo de las medidas de error de pronóstico 2013-05-30.

Fuente: Autor.

Cuadro comparativo económico promedio 30 de mayo 2013				
	Demanda Real (USD)	Pre despacho (USD)	R. Neuronal sin incluir la variable del clima (USD)	R. Neuronal incluyendo la variable del clima (USD)
Demanda Base	122.865,04	127.899,03	121.417,37	123.732,44
Demanda Media	213.799,95	224.680,32	203.382,58	199.512,28
Demanda Punta	246.755,92	259.770,63	235.556,74	237.593,52

Tabla 43. Cuadro comparativo económico 2013-05-30.

Fuente: Autor.

En los gráficos presentados anteriormente se muestra una comparación de los perfiles de demanda reales, predespachos de demanda realizado por el CENACE y los perfiles de demanda obtenidos por las redes neuronales, para los días 28, 29 y 30 de mayo del 2013, se observa que las curvas de los perfiles de demanda obtenidas mediante las redes neuronales siguen la tendencia de la curva de demanda real con la particularidad de no abastecer la demanda del sistema en todas las horas del día; para realizar el análisis técnico-económico se presentan cuadros comparativos al pie de los gráficos de perfil de demanda, se observa que el MAPE de los pronósticos obtenidos de las redes neuronales de los días 28, 29 y 30 de mayo del 2013 no excede el $\pm 2.5\%$ es decir se encuentra dentro del límite establecido del $\pm 5\%$.

A continuación del cuadro comparativo de las medidas de error , se presenta un cuadro económico comparativo del valor en dólares que cuesta abastecer al sistema en cada una de los periodos horarios (base, media y punta), la comparación se realiza entre el predespacho que realiza el CENACE, los pronósticos obtenidos mediante las redes neuronales en los dos casos de estudio, y el costo de abastecer la demanda real, se observa que el costo de abastecer al sistema en el caso de los pronósticos de las redes neuronales y el predespacho se relaciona directamente con las medidas de error de pronóstico, debido a que si el MAE y el MAPE están cercanos a cero el costo de abastecer al sistema será semejante al costo real, evidentemente el costo de la demanda del sistema en el caso de los pronósticos de las redes neuronales es inferior al del predespacho debido a que no logra abastecer la demanda en todas las horas del día, de los resultados obtenidos del análisis se concluye que los pronósticos obtenidos de las redes neuronales son aceptable debido a que se encuentra dentro del límite establecido pero sujeto a un ajuste en la base de datos de demanda histórica para llegar a cumplir la condición de abastecer al sistema.

CONCLUSIONES

1. Para realizar un pronóstico de la demanda de energía eléctrica a corto plazo, es necesario disponer de información confiable y suficiente para desarrollar un análisis detallado de toda la información disponible que se relacione con el consumo de la energía eléctrica, horarios, fechas, tipos de consumidores, entre otras variables. Debido al alto grado de complejidad del análisis, la eficiencia del pronóstico de corto plazo, depende directamente de la robustez del modelo de pronóstico, y sobre todo de las técnicas a utilizar para el mejoramiento de su precisión.

2. Como resultado del desarrollo del presente trabajo de tesis, se confirmaron algunos aspectos obtenidos de los trabajos investigados y otros como resultado de la investigación, como son:
 - La calidad y veracidad de los datos, es información fundamental para el desarrollo de modelos de pronóstico adecuados.
 - El método de cuartiles y prueba de Grubbs, son técnicas más robustas que la gráfica de cajas y alambres, para detectar valores atípicos.
 - La demanda de energía eléctrica en forma generalizada, sigue un perfil de carga horario definido, el cual se encuentra afectado y sujeto a modificaciones según las características de los usuarios y de su consumo considerando para el efecto la fecha y hora y variables climáticas.

3. Al realizar el estudio incluyendo los efectos de variables exógenas como fue la variable del clima para pronosticar la demanda de energía eléctrica, se observó que las medidas de error de pronóstico no tienen mayor variación en relación al pronóstico realizado sin incluir la variable del clima como entrada a la red, de los dos casos de estudios se obtuvieron resultados aceptables ya que su eficiencia es del 95% en la mayoría de los casos, al observar el comportamiento de las redes neuronales se puede concluir que las variables de entrada a la red neuronal más importantes al realizar un pronóstico son: variables del tiempo (hora, fecha, días laborables y no laborables) y variable de demanda histórica, la variable de demanda

histórica se podría decir que es la más importante debido a que ya fue afectada por las variables exógenas, y en base a esta se genera la mayoría de datos de la matriz de predictores de entrada a la red neuronal.

4. La eficiencia de un pronóstico de demanda eléctrica a corto plazo depende mucho del tiempo que se emplee para entrenar a la red neuronal, por su naturaleza de aprender por medio de experiencias se debe insistir en realizar varios entrenamientos y pruebas antes de seleccionar la red con la cual se va a realizar el pronóstico, el requerimiento principal es contar con una base de datos de demanda eléctrica histórica confiable y veraz que debe contener información de al menos seis años anteriores.
5. En el capítulo III se llevó a cabo el procedimiento para la selección del número de neuronas a ser utilizadas en la capa oculta de las redes neuronales, se observó que el número de neuronas en la capa oculta varía dependiendo al número de entradas por lo que se debe realizar diferentes entrenamientos para obtener mejor ajuste de la red neuronal, los criterios utilizados para la determinación del número de neuronas en la capa oculta fueron los siguientes:
 - El número de neuronas en la capa oculta no puede ser mayor a dos veces el número de entradas[12],
 - No hay manera de determinar el número óptimo de neuronas en la capa oculta sin antes entrenar varias redes y analizar los resultados de pronóstico obtenidos[12].

Basándose en dichos criterios se determinó para los dos casos el número de neuronas en la capa oculta sea de cuatro; si se selecciona un número incorrecto de neuronas en la capa oculta se sobrestima o se subestima los valores de la red proporcionando pronósticos erróneos.

6. Al pasar el tercer día del pronóstico el algoritmo de solución de redes neuronales presenta resultados de pronóstico que no cumplen con la condición de abastecer al sistema como lo hace en los tres días anteriores, esto se debe a que no se cuenta con

una base histórica de datos suficiente para que el algoritmo aprenda y generalice de manera adecuada, sin embargo los datos de pronóstico que se obtienen del algoritmo de solución de redes neuronales se encuentran dentro del límite $\pm 5\%$ establecido en el capítulo III, entonces se puede decir que en general los pronósticos obtenidos para estos días son aceptables pero sujetos a un ajuste en la base histórica de datos para cumplir con la condición de abastecer al sistema en todas las horas del día.

7. Debido a que no existe ninguna metodología establecida que mencione como seleccionar el porcentaje de datos de entrenamiento, prueba y validación, se efectuó una serie de ensayos durante el proceso de entrenamiento de la red neuronal para llegar a concluir que: el seleccionar adecuadamente el porcentaje de los datos para el entrenamiento de la red neuronal, es de vital importancia para obtener resultados óptimos en los pronósticos, ya que una mala selección de dichos porcentajes altera en la operatividad de la red neuronal, el criterio utilizado para la selección de porcentaje de los datos de entrenamiento, prueba y validación fue el siguiente: el 60% de los datos de entrada de la red neuronal se utilizó para realizar el entrenamiento de la red, se seleccionó dicho porcentaje debido a que la red se ajusta iteración a iteración en base al error de entrenamiento, el 30% de los datos de entrada a la red neuronal para realizar la validación, se seleccionó dicho porcentaje debido a que la validación mide la capacidad de generalización de red y para el entrenamiento cuando encuentre la mejor generalización, el 10% de los datos de entrada a la red neuronal se seleccionó para realizar las pruebas de la red, es un porcentaje mínimo ya que es una medida independiente durante y después del entrenamiento de la red además de que no tiene ninguna efecto sobre el entrenamiento de la red.

8. Los resultados técnicos y económicos que se obtuvieron de los pronósticos de las redes neuronales en el corto plazo del S.N.I para los días 25, 26, 27 de mayo del 2013, fueron óptimos debido a que cumplen con la condición establecida en el capítulo III de no exceder el $\pm 5\%$ en el MAPE y además con la condición de

abastecer al sistema en todas las horas del día, en el análisis económico se demostró que los pronósticos de las redes neuronales tienen un costo menor de abastecer al sistema que el predespacho que realiza el CENACE, por lo que se puede concluir que los pronósticos adquiridos de las redes neuronales para los días mencionados anteriormente fueron exitosos.

9. Los resultados técnicos y económicos que se obtuvieron de los pronósticos de las redes neuronales en el corto plazo del S.N.I para los días 28, 29, 30 de mayo del 2013, fueron aceptables debido a que cumplen con la condición establecida en el capítulo III de no exceder el $\pm 5\%$ en el MAPE, sin embargo no cumplen con la condición de abastecer al sistema en todas las horas del día, en el análisis económico se demostró que los pronósticos de las redes neuronales tienen un costo menor de abastecer al sistema que el predespacho que realiza el CENACE, el costo es menor debido a que los pronósticos obtenidos de las redes neuronales no abastecen al sistema en todas las horas del día, por lo que se puede concluir que los pronósticos adquiridos de las redes neuronales para los días mencionados son aceptable debido a que se encuentra dentro del límite establecido pero sujeto a un ajuste en la base de datos de demanda histórica para llegar a cumplir la condición de abastecer al sistema

RECOMENDACIONES

1. En el presente trabajo de tesis se realizó un pronóstico de demanda eléctrica incluyendo la variable del clima, denominado caso2, la variable del clima que se utilizó como dato de entrada a la red neuronal se encuentra representada por: temperatura y el punto de rocío.

La temperatura del país para cada hora del día se obtuvo al realizar el promedio de la temperatura de la estación climática del aeropuerto de Guayaquil como referencia de la región costa, la temperatura de la estación climática del aeropuerto de Quito como referencia de la región Sierra y la temperatura de la estación climática del aeropuerto del Coca como referencia de la región amazónica; mientras que, el punto de rocío del país para cada hora del día se obtuvo al realizar el promedio por cada punto de medición.

De esta manera se obtuvieron resultados de pronóstico óptimos, sin embargo y de poder obtener la influencia del clima, como variable significativa en el pronóstico de la demanda, se recomienda extrapolar el uso de redes neuronales en el pronóstico de demanda en corto plazo para que se efectúen en cada una de las distribuidoras sectoriales, debido a que es más factible incorporar la variable del clima de un área definida con lo cual se obtendrá la predicción óptima de la demanda en períodos futuros.

2. Para aplicaciones futuras del pronóstico de demanda en el corto plazo, se recomienda tomar en cuenta otras variables exógenas adicionales que puedan ser sensibles en el pronóstico, con el fin de que el mismo sea más afinado y permita seguir la tendencia de la demanda real.
3. Se sugiere realizar el escalamiento de los datos de demanda eléctrica que serán utilizados en el pronóstico, es decir transformarlos en valores por unidad, para facilitar el procesamiento y análisis de los mismo, y por consecuencia obtener mejores resultados disminuyendo el porcentaje en las medidas de error en el pronóstico.

4. Con experiencia obtenida en la realización del presente proyecto de tesis y con la sustentación teórica expuesta en la conclusión número 7, se sugiere seleccionar como porcentaje de datos de entrenamiento, prueba y validación de una red neuronal en el pronóstico de demanda a corto plazo, los siguientes valores:
- Entrenamiento: 60% de los datos.
 - Prueba: 30% de los datos.
 - Validación: 10% de los datos.

REFERENCIAS

- [1] Ing Mat. Bertha Liliana Llerena Poveda, “SISTEMA NACIONAL INTERCONECTADO , MEDIANTE LOS MÉTODOS DE SERIES TEMPORALES Y REDES NEURONALES,” QUITO-ECUADOR, APARTADO 17-01-2759.
- [2] CONELEC, “DEMANDA ELÉCTRICA,” in PLAN MAESTRO DE ELECTRIFICACIÓN 2012-2021, PICHINCHA-QUITO, 2012, pp. 97–133.
- [3] Conelec, “Plan Maestro de electrificación 2013-2022,” 2013, p. 256.
- [4] P. O. MONDRAGÓN, “PRONÓSTICO DE LA DEMANDA DE ENERGÍA ELÉCTRICA A CORTO PLAZO UTILIZANDO UNA RED NEURONAL ÓPTIMA.,” INSTITUTO POLITÉCNICO NACIONAL, 2011.
- [5] F. O. Ramírez Pérez, Introducción a las series de tiempo Métodos paramétricos. 2007, p. 83.
- [6] M. P. Jara and J. Rosel, Análisis de series temporales Un ejemplo de aplicación en ámbitos psicológicos. p. 127.
- [7] L. P. Ing Mat. Bertha Liliana, “ESTIMACIÓN DE LA DEMANDA ELÉCTRICA A CORTO PLAZO DEL SISTEMA NACIONAL INTERCONECTADO, MEDIANTE LOS MÉTODOS DE SERIES TEMPORALES Y REDES NEURONALES,” QUITO-ECUADOR.
- [8] X. Rodríguez, “Eficiencia Energética y Desarrollo Sostenible en el Ecuador,” 2013. [Online]. Available: <http://www.econintsa.ec/eficiencia-energetica-y-desarrollo-sostenible-en-el-ecuador/>.
- [9] V. H. Hinojosa, “SUMINISTRO DE ENERGÍA ELÉCTRICA : PRONÓSTICO DE DEMANDA DE MUY CORTO PLAZO Y PRONÓSTICO DE LOS PRECIOS SPOT DE CORTO PLAZO,” pp. 77–85.
- [10] D. C. Montgomery and G. C. Runger, Applied Statistics and Probability for Engineers Third Edition, Third edit. Arizona, 2003, p. 976.
- [11] D. G. J. Ing and A. C. M. Ing, “Predicción de la demanda eléctrica de corto plazo mediante Redes Neuronales Artificiales .,” no. 1, pp. 2–5, 2003.
- [12] S. Kevin, Applying Neural Networks a Practical Guide, Third prin. San Francisco, CA 94104, 2001, p. 291.

- [13] S. Ledesma, “Las Redes Neuronales implementación y Las Redes Neuronales Artificiales (ANN),” in Fifth Mexican International Conference on Artificial Intelligence, p. 50.
- [14] JAIRO A. MENDOZA VARGAS, “PRONÓSTICO DE CARGA A CORTO PLAZO UTILIZANDO REDES NEURONALES ARTIFICIALES,” *Scientia et Technica* Año XII, no. 32, pp. 175–180, 2006.
- [15] L. A. F. Jiménez, “Modelos avanzados para la predicción a corto plazo de la producción eléctrica en parques eólicos.,” UNIVERSIDAD DE LA RIOJA, 2008.
- [16] K. Fei, “Implementation of Neural & Neuro- Fuzzy Approaches for Short-Term Electricity Demand Forecasting,” in *Power System Technology - POWERCON 2004*, 2004, no. November, pp. 21–24.
- [17] F. X. Diebold, *Elementos de Pronóstico*. Mexico DF.: , 2001, p. 330.
- [18] L. L. Grigsby, *Electric Power Generation, Transmission, and Distribution.*, Tercera ed. 2012, p. 512.
- [19] http://www.mathworks.com/videos/electricity-load-and-price-forecasting-with-matlab-82037.html?form_seq=conf840&&wfsid=5058243
- [20] http://www.mundomanz.com/meteo_p/byind?countr=ECUADOR&ind=84203&year=2011&month=04&day=31&n_days=1&time=all&trans=DE&action=display
- [21] E. N. Sánchez Camperos and A. G. A. Yolanda, *Redes neuronales conceptos fundamentales y aplicaciones al control automático*. 2006
- [22] M. Paulescu, E. Paulescu, P. Gravila and V. Badescu, *Weather Modeling and Forecasting of PV System Operation*, 2013
- [23] Francis Diebold, *Elementos de Pronóstico*, 2001
- [24] Mrs. J. P. Rothe, Dr. A.K. Wadhvani and Dr. Mrs. S. Wadhvani “Short Term Load Forecasting Using Multi Parameter Regression” *International Journal of Computer Science and Information Security*, Vol. 6 no. 2, 2009.
- [25] Ing. D. J. García, Ing. A. Cabrera “Predicción de la demanda eléctrica de corto plazo mediante Redes Neuronales Artificiales ” *SIE*, 2003.

ANEXOS

ANEXO 1

Script de Matlab para generar la matriz de predictores como entradas de la red Neuronal, para el caso 1, pronóstico de demanda a corto plazo sin incluir la variable del clima como entrada a la red neuronal.

```

function [X, dates, labels] = genPredictors(data, term, holidays)
% La función GENPREDICTORS genera una matriz de variables de
predicción para el modelo de previsión de cargas.
% USO:
% [X, fechas, etiquetas] = genPredictors(Datos, Plazo, días festivos)
%
% Entradas:
% Datos%: Una matriz de conjunto de datos de información de tiempo y
% carga histórico
% Plazo      : 'largo' o 'corto' que indica el horizonte del
% pronóstico.
%
% Predictores como la carga del día anterior no se
% incluyen en el pronóstico a largo plazo.
% Días festivos: es un vector de las vacaciones. Si no se especifica,
% las vacaciones son generadas por la función CREATEHOLIDAYDATES
%
% Salidas:
% X      : Una matriz de datos de predicción, donde cada fila
% corresponde a una observación (carga por hora) y cada columna
% corresponde a una variable
% fechas: Un vector de fechas para cada observación
% etiquetas: Una matriz de celdas en cadenas que describen cada
predictor
% Convertir fechas en una representación numérica
try
    fecha = data.NumDate;
catch %#ok<CTCH>
    fecha = datenum(data.Fecha, 'yyyy-mm-dd HH:MM:SS') + (data.Hora-
1)/24;
end
if all(floor(fecha)==fecha) % Verdadero si las fechas no incluyen
ninguna información horas
    fechas = fechas + (data.Hora-1)/24;
end
% Proceso de días festivos
if nargin < 3 || isempty(festivos)
    festivos = createHolidayDates(min(fecha), max(fecha));
else
    festivos = datenum(festivos);
end
% Creación de predictores

% Entradas de pronóstico de corto plazo
% Entradas de carga eléctrica rezagadas
CargaDeLaMismaHoraDelDiaAnterior = [NaN(24,1); data.Carga(1:end-24)];
CargaDeLaMismaHoraDeLaSemanaAnterior = [NaN(168,1); data.Carga(1:end-
168)];
CargaPromedioDeLas24HorasAnteriores = filter(ones(1,24)/24, 1,
data.Carga);
%prev24HrAveLoad = filter(ones(1,24)/24, 1, [NaN(24,1);
data.SYSLoad(1:end-24)]);

```

```

% Predictores de fechas
DiasEntreSemana = weekday(fecha);

% Días no laborables
DiasLaborables = ~ismember(floor(fechas),festivos) &
~ismember(diasentresemana,[6 7]);
%[~,~, Diaslaborables ] = createHolidayDates(data.NumDate);

if strcmpi(term, 'long', 4);
    % Predictores de pronóstico a largo plazo
    X = [data.temperatura data.PuntoDeRocio daily5dayHighAve
daily5dayLowAve data.Hora DiasDeLaSemana DiaLaborable ];
    labels = {'Temperatura', 'PuntoDeRocio', 'Prev5DayHighAve',
'Prev5DayLowAve', 'Hora', 'DiasDeLaSemana', 'DiasLaborables '};
else
    % Predictores de pronóstico de corto plazo
    X = [data.Hora DiasDeLaSemana DiaLaborable
CargaDeLaMismaHoraDeLaSemanaAnterior CargaDeLaMismaHoraDelDiaAnterior
CargaPromedioDeLas24HorasAnteriores];
    etiquetas = {'Hora', 'DiasDeLaSemana', 'DiasLaborables',
'CargaDeLaMismaHoraDeLaSemanaAnterior',
'CargaDeLaMismaHoraDelDiaAnterior',
'CargaPromedioDeLas24HorasAnteriores'};
end

function y = rep24(x)
y = repmat(x(:), 1, 24)';
y = y(:);

```

ANEXO 2

Script de Matlab para generar la matriz de predictores como entradas de la red Neuronal, para el caso 2, pronóstico de demanda a corto plazo incluyendo la variable del clima como entrada a la red neuronal.

```

function [X, dates, labels] = genPredictors(data, term, holidays)
% La función GENPREDICTORS genera una matriz de variables de
predicción para el modelo de previsión de cargas.
% USO:
% [X, fechas, etiquetas] = genPredictors(Datos, Plazo, días festivos)
%
% Entradas:
% Datos%: Una matriz de conjunto de datos de información de tiempo y
% carga histórico
% Plazo      : 'largo' o 'corto' que indica el horizonte del
% pronóstico.
%           Predictores como la carga del día anterior no se
% incluyen en el pronóstico a largo plazo.
% Días festivos: es un vector de las vacaciones. Si no se especifica,
% las vacaciones son generadas por la función CREATEHOLIDAYDATES
%
% Salidas:
% X      : Una matriz de datos de predicción, donde cada fila
% corresponde a una observación (carga por hora) y cada columna
% corresponde a una variable
% fechas: Un vector de fechas para cada observación
% etiquetas: Una matriz de celdas en cadenas que describen cada
predictor
% Convertir fechas en una representación numérica
try
    fecha = data.NumDate;
catch %#ok<CTCH>
    fecha = datenum(data.Fecha, 'yyyy-mm-dd HH:MM:SS') + (data.Hora-
1)/24;
end
if all(floor(fecha)==fecha) % Verdadero si las fechas no incluyen
ninguna información horas
    fechas = fechas + (data.Hora-1)/24;
end
% Proceso de días festivos
if nargin < 3 || isempty(festivos)
    festivos = createHolidayDates(min(fecha), max(fecha));
else
    festivos = datenum(festivos);
end
% Creación de predictores

% Entradas de pronóstico de corto plazo
% Entradas de carga eléctrica rezagadas
CargaDeLaMismaHoraDelDiaAnterior = [NaN(24,1); data.Carga(1:end-24)];
CargaDeLaMismaHoraDeLaSemanaAnterior = [NaN(168,1); data.Carga(1:end-
168)];
CargaPromedioDeLas24HorasAnteriores = filter(ones(1,24)/24, 1,
data.Carga);
%prev24HrAveLoad = filter(ones(1,24)/24, 1, [NaN(24,1);
data.SYSLoad(1:end-24)]);
data.SYSLoad(1:end-24)];

```

```

% Predictores de fechas
DiasEntreSemana = weekday(fecha);

% Días no laborables
DiasLaborables = ~ismember(floor(fechas),festivos) &
~ismember(diasentresemana,[6 7]);
%[~,~, Diaslaborables ] = createHolidayDates(data.NumDate);

if strcmpi(term, 'long', 4);
    % Predictores de pronóstico a largo plazo
    X = [data.temperatura data.PuntoDeRocio daily5dayHighAve
daily5dayLowAve data.Hora DiasDeLaSemana DiaLaborable ];
    labels = {'Temperatura', 'PuntoDeRocio', 'Prev5DayHighAve',
'Prev5DayLowAve', 'Hora', 'DiasDeLaSemana ', 'DiasLaborables '};
else
    % Predictores de pronóstico de corto plazo
    X = [data.Temperatura data.PuntoDeRocio data.Hora DiasDeLaSemana
DiaLaborable CargaDeLaMismaHoraDeLaSemanaAnterior
CargaDeLaMismaHoraDelDiaAnterior CargaPromedioDeLas24HorasAnteriores];
    etiquetas = {'Temperatura', 'PuntoDeRocio', 'Hora',
'DiasDeLaSemana', 'DiaLaborable',
'CargaDeLaMismaHoraDeLaSemanaAnterior', '
CargaDeLaMismaHoraDelDiaAnterior',
'CargaPromedioDeLas24HorasAnteriores'};
end

function y = rep24(x)
y = repmat(x(:), 1, 24)';
y = y(:);

```

ANEXO 3

Script de Matlab para calcular el pronóstico de demanda eléctrica en corto plazo en el SIN, sin incluir la variable del tiempo, caso1.


```

function y = loadForecast(date, hora, isHoliday)
% LOADFORECAST realiza una previsión de carga de un día de antelación
% utilizando un pre-entrenado Neural-red%
% USO:
% y = loadForecast(modelo, fecha, hora, temperatura, DiaLaborable))
% Proceso de Entradas
date = datenum(date);
if date < 7e5 % Convierte a formato Excel la fecha numérica de MATLAB
% numérica si es necesario
date = x2mdate(date);
end
% Compruebe si la fecha es un día de fiesta
if iscell(isHoliday)
isHoliday = isHoliday{1};
end
if ischar(isHoliday)
if strcmpi(isHoliday(1), 'N')
isWorkingDay = true;
else
isWorkingDay = false;
end
else
isWorkingDay = ~isHoliday;
end
isWorkingDay = logical(isWorkingDay) & ~ismember(weekday(date), [6 7]);

% Importa las cargas históricas de la base de datos
try
data = fetchPronosticodemanda(date-7, date-1);
catch ME %#ok<NASGU>
% Importa las cargas históricas del archivo MAT
s = load('Data\Pronosticodemanda.mat');
data = s.data;
ind = data.NumDate >= date-7 & floor(data.NumDate) <= date-1;
%data.Hour = data.Hour(ind);
%data.DryBulb = data.DryBulb(ind);
%data.DewPnt = data.DewPnt(ind);
data.SYSLoad = data.SYSLoad(ind);
data.NumDate = data.NumDate(ind);
b = load('Data\demultmayo.mat');
datos = b.datos;
dreal=datos.SYSLoad;

end
if isempty(data.SYSLoad)
error(' Datos históricos no es suficiente para el pronóstico .');
end

ave24 = filter(ones(25,1)/25, 1, data.SYSLoad);
loadPredictors = [data.SYSLoad(1:25) data.SYSLoad(end-24:end) ave24(end-
24:end)];

```

```

% Creación de la matriz de predictores
% Drybulb, Dewpnt, Hour, Day, isWkDay, PrevWeek, PrevDay, Prev24
X = [hora(1:25)' weekday(date)*ones(25,1) isWorkingDay*ones(25,1)
loadPredictors];
% Cargar modelos de redes neuronales
try
    % Cargar desde un lugar donde se pueden almacenar modelos actualizados
    model1 = load('C:\Temp\Forecaster\NNModel.mat');
    %model2 = load('C:\Temp\Forecaster\TreeModel.mat');
catch %#ok<CTCH>
    model1 = load('Models\NNModel.mat');
    % model2 = load('Models\TreeModel.mat');
end

% Realizar Predicción
try
    y1 = sim(model1.net, X)';

catch ME
    % Para propósitos de depuración en caso de necesidad
    save C:\error.mat ME model1 %model2
    y1 = zeros(25,1);
end
%y2 = predict(model2.model, X);

% Crear gráfico del perfil de carga
fig = clf;
if isdeployed
    set(fig, 'Visible', 'off')
end

if date == 735379
plot(dreal(1:25,1)/1e3, '-');hold all;plot(y1/1e3, '-');hold all;;hold
off;figure(gcf);
xlabel('Hora');
ylabel('Carga (x1000 MW)');
title(sprintf('Pronóstico del perfil de carga para %s', datestr(date)))
grid on;
legend('Demanda Real', 'Location', 'best', 'Pronóstico Red
neuronal', 'Location', 'best');
print -dmeta
err = dreal(1:25,1)-(y1);
errpct = abs(err)./(datos.SYSLoad(1:25,1));
MAE = mean(abs(err));
MAPE = mean(errpct)*100;
fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error
(MAE): %0.2f MWh\', ...
    MAPE, MAE)
end

```

```

if date == 735380
plot(dreal(26:50,1)/1e3,'.-');hold all; plot(y1/1e3, '-.-');hold all;;hold
off;figure(gcf);
xlabel('Hora');
ylabel('Carga (x1000 MW)');
title(sprintf('Pronóstico del perfil de carga para %s', datestr(date)))
grid on;
legend('Demanda Real','Location','best','Pronóstico Red
neuronal','Location','best');
print -dmeta
err = dreal(26:50,1)-(y1);
errpct = abs(err)./(datos.SYSLoad(26:50,1));
MAE = mean(abs(err));
MAPE = mean(errpct)*100;
fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error
(MAE): %0.2f MWh\',...
        MAPE, MAE)
end
if date == 735381
plot(dreal(51:75,1)/1e3,'.-');hold all; plot(y1/1e3, '-.-');hold all;;hold
off;figure(gcf);
xlabel('Hora');
ylabel('Carga (x1000 MW)');
title(sprintf('Pronóstico del perfil de carga para %s', datestr(date)))
grid on;
legend('Demanda Real','Location','best','Pronóstico Red
neuronal','Location','best');
print -dmeta
err = dreal(51:75,1)-(y1);
errpct = abs(err)./(datos.SYSLoad(51:75,1));
MAE = mean(abs(err));
MAPE = mean(errpct)*100;
fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error
(MAE): %0.2f MWh\',...
        MAPE, MAE)
end
if date == 735382
plot(dreal(76:100,1)/1e3,'.-');hold all; plot(y1/1e3, '-.-');hold all;;hold
off;figure(gcf);
xlabel('Hora');
ylabel('Carga (x1000 MW)');
title(sprintf('Pronóstico del perfil de carga para %s', datestr(date)))
grid on;
legend('Demanda Real','Location','best','Pronóstico Red
neuronal','Location','best');
print -dmeta
err = dreal(76:100,1)-(y1);
errpct = abs(err)./(datos.SYSLoad(76:100,1));
MAE = mean(abs(err));
MAPE = mean(errpct)*100;
fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error
(MAE): %0.2f MWh\',...
        MAPE, MAE)
end

```

```

if date == 735383
plot(dreal(101:125,1)/1e3,'.-');hold all; plot(y1/1e3, '-. ');hold all;;hold
off;figure(gcf);
xlabel('Hora');
ylabel('Carga (x1000 MW)');
title(sprintf('Pronóstico del perfil de carga para %s', datestr(date)))
grid on;
legend('Demanda Real','Location','best','Pronóstico Red
neuronal','Location','best');
print -dmeta
err = dreal(101:125,1)-(y1);
errpct = abs(err)./(datos.SYSLoad(101:125,1));
MAE = mean(abs(err));
MAPE = mean(errpct)*100;
fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error
(MAE): %0.2f MWh\',...
    MAPE, MAE)
end
if date == 735384
plot(dreal(126:150,1)/1e3,'.-');hold all; plot(y1/1e3, '-. ');hold all;;hold
off;figure(gcf);
xlabel('Hora');
ylabel('Carga (x1000 MW)');
title(sprintf('Pronóstico del perfil de carga para %s', datestr(date)))
grid on;
legend('Demanda Real','Location','best','Pronóstico Red
neuronal','Location','best');
print -dmeta
err = dreal(126:150,1)-(y1);
errpct = abs(err)./(datos.SYSLoad(126:150,1));
MAE = mean(abs(err));
MAPE = mean(errpct)*100;
fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error
(MAE): %0.2f MWh\',...
    MAPE, MAE)
end
if date == 735385
plot(dreal(151:175,1)/1e3,'.-');hold all; plot(y1/1e3, '-. ');hold all;;hold
off;figure(gcf);
xlabel('Hora');
ylabel('Carga (x1000 MW)');
title(sprintf('Pronóstico del perfil de carga para %s', datestr(date)))
grid on;
legend('Demanda Real','Location','best','Pronóstico Red
neuronal','Location','best');
print -dmeta
err = dreal(151:175,1)-(y1);
errpct = abs(err)./(datos.SYSLoad(151:175,1));
MAE = mean(abs(err));
MAPE = mean(errpct)*100;
fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error
(MAE): %0.2f MWh\',...
    MAPE, MAE)
end

y = y1;

```

ANEXO 4

Script de Matlab para calcular el pronóstico de demanda eléctrica en corto plazo en el SIN, incluyendo la variable del tiempo, caso2.

```

function y = loadForecast(date, hora, isHoliday)
LOADFORECAST realiza una previsión de carga de un día de antelación
% utilizando un pre-entrenado Neural-red%
% USO:
% y = loadForecast(modelo, fecha, hora, temperatura, DiaLaborable)
% Proceso de Entradas
date = datenum(date);
if date < 7e5 % Convierte a formato Excel la fecha numérica de MATLAB
% numérica si es necesario
date = x2mdate(date);
end
% Compruebe si la fecha es un día de fiesta
if iscell(isHoliday)
isHoliday = isHoliday{1};
end
if ischar(isHoliday)
if strcmpi(isHoliday(1), 'N')
isWorkingDay = true;
else
isWorkingDay = false;
end
else
isWorkingDay = ~isHoliday;
end
isWorkingDay = logical(isWorkingDay) & ~ismember(weekday(date), [6 7]);

% Importa las cargas históricas de la base de datos
try
data = fetchPronosticodemanda(date-7, date-1);
catch ME %#ok<NASGU>
% Importa las cargas históricas del archivo MAT
s = load('Data\Pronosticodemanda.mat');
data = s.data;
ind = data.NumDate >= date-7 & floor(data.NumDate) <= date-1;
data.Hour = data.Hour(ind);
data.DryBulb = data.DryBulb(ind);
data.DewPnt = data.DewPnt(ind);
data.SYSLoad = data.SYSLoad(ind);
data.NumDate = data.NumDate(ind);
b = load('Data\demultmayo.mat');
datos = b.datos;
dreal=datos.SYSLoad;

end
if isempty(data.SYSLoad)
error('Datos históricos no es suficiente para el pronóstico.');
```

```

end

ave24 = filter(ones(25,1)/25, 1, data.SYSLoad);
loadPredictors = [data.SYSLoad(1:25) data.SYSLoad(end-24:end) ave24(end-24:end)];

```

```

% Crear matriz de Predictores
% Drybulb, Dewpnt, Hour, Day, isWkDay, PrevWeek, PrevDay, Prev24
X = [hora(1:25)' weekday(date)*ones(25,1) isWorkingDay*ones(25,1)
loadPredictors];
% Cargar modelos de redes neuronales
try
    % Cargar desde un lugar donde se pueden almacenar modelos actualizados
    model1 = load('C:\Temp\Forecaster\NNModel.mat');
    %model2 = load('C:\Temp\Forecaster\TreeModel.mat');
catch %#ok<CTCH>
    model1 = load('Models\NNModel.mat');
    % model2 = load('Models\TreeModel.mat');
end

% Realizar Pronóstico
try
    y1 = sim(model1.net, X)';

catch ME
    % Para propósitos de depuración en caso de necesidad
    save C:\error.mat ME model1 %model2
    y1 = zeros(25,1);
end
%y2 = predict(model2.model, X);

% Crear gráfico del perfil de carga
fig = clf;
if isdeployed
    set(fig,'Visible','off')
end

if date == 735379
plot(dreal(1:25,1)/1e3,'.-');hold all;plot(y1/1e3, '-');hold all;;hold
off;figure(gcf);
xlabel('Hora');
ylabel('Carga (x1000 MW)');
title(sprintf('Pronóstico del perfil de carga para %s', datestr(date)))
grid on;
legend('Demanda Real','Location','best','Pronóstico Red
neuronal','Location','best');
print -dmeta
err = dreal(1:25,1)-(y1);
errpct = abs(err)./(datos.SYSLoad(1:25,1));
MAE = mean(abs(err));
MAPE = mean(errpct)*100;
fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error
(MAE): %0.2f MWh',...
        MAPE, MAE)
end

```

```

if date == 735380
plot(dreal(26:50,1)/1e3,'.-');hold all; plot(y1/1e3, '-');hold all;;hold
off;figure(gcf);
xlabel('Hora');
ylabel('Carga (x1000 MW)');
title(sprintf('Pronóstico del perfil de carga para %s', datestr(date)))
grid on;
legend('Demanda Real','Location','best','Pronóstico Red
neuronal','Location','best');
print -dmeta
err = dreal(26:50,1)-(y1);
errpct = abs(err)./(datos.SYSLoad(26:50,1));
MAE = mean(abs(err));
MAPE = mean(errpct)*100;
fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error
(MAE): %0.2f MWh\\',...
        MAPE, MAE)
end
if date == 735381
plot(dreal(51:75,1)/1e3,'.-');hold all; plot(y1/1e3, '-');hold all;;hold
off;figure(gcf);
xlabel('Hora');
ylabel('Carga (x1000 MW)');
title(sprintf('Pronóstico del perfil de carga para %s', datestr(date)))
grid on;
legend('Demanda Real','Location','best','Pronóstico Red
neuronal','Location','best');
print -dmeta
err = dreal(51:75,1)-(y1);
errpct = abs(err)./(datos.SYSLoad(51:75,1));
MAE = mean(abs(err));
MAPE = mean(errpct)*100;
fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error
(MAE): %0.2f MWh\\',...
        MAPE, MAE)
end
if date == 735382
plot(dreal(76:100,1)/1e3,'.-');hold all; plot(y1/1e3, '-');hold all;;hold
off;figure(gcf);
xlabel('Hora');
ylabel('Carga (x1000 MW)');
title(sprintf('Pronóstico del perfil de carga para %s', datestr(date)))
grid on;
legend('Demanda Real','Location','best','Pronóstico Red
neuronal','Location','best');
print -dmeta
err = dreal(76:100,1)-(y1);
errpct = abs(err)./(datos.SYSLoad(76:100,1));
MAE = mean(abs(err));
MAPE = mean(errpct)*100;
fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error
(MAE): %0.2f MWh\\',...
        MAPE, MAE)
end

```



```


if date == 735383
plot(dreal(101:125,1)/1e3,'.-');hold all; plot(y1/1e3, '-. ');hold all;;hold
off;figure(gcf);
xlabel('Hora');
ylabel('Carga (x1000 MW)');
title(sprintf('Pronóstico del perfil de carga para %s', datestr(date)))
grid on;
legend('Demanda Real','Location','best','Pronóstico Red
neuronal','Location','best');
print -dmeta
err = dreal(101:125,1)-(y1);
errpct = abs(err)./(datos.SYSLoad(101:125,1));
MAE = mean(abs(err));
MAPE = mean(errpct)*100;
fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error
(MAE): %0.2f MWh\',...
        MAPE, MAE)
end
if date == 735384
plot(dreal(126:150,1)/1e3,'.-');hold all; plot(y1/1e3, '-. ');hold all;;hold
off;figure(gcf);
xlabel('Hora');
ylabel('Carga (x1000 MW)');
title(sprintf('Pronóstico del perfil de carga para %s', datestr(date)))
grid on;
legend('Demanda Real','Location','best','Pronóstico Red
neuronal','Location','best');
print -dmeta
err = dreal(126:150,1)-(y1);
errpct = abs(err)./(datos.SYSLoad(126:150,1));
MAE = mean(abs(err));
MAPE = mean(errpct)*100;
fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error
(MAE): %0.2f MWh\',...
        MAPE, MAE)
end
if date == 735385
plot(dreal(151:175,1)/1e3,'.-');hold all; plot(y1/1e3, '-. ');hold all;;hold
off;figure(gcf);
xlabel('Hora');
ylabel('Carga (x1000 MW)');
title(sprintf('Pronóstico del perfil de carga para %s', datestr(date)))
grid on;
legend('Demanda Real','Location','best','Pronóstico Red
neuronal','Location','best');
print -dmeta
err = dreal(151:175,1)-(y1);
errpct = abs(err)./(datos.SYSLoad(151:175,1));
MAE = mean(abs(err));
MAPE = mean(errpct)*100;
fprintf('Mean Absolute Percent Error (MAPE): %0.2f%% \nMean Absolute Error
(MAE): %0.2f MWh\',...
        MAPE, MAE)
end
y = y1;

```


ANEXO 5

Diferencia entre el valor de demanda real y demanda pronosticada, caso1 , período
01-01-2010 - a 24-05-2013.


Diferencia entre la Demanda Real y el Pronóstico de la red neuronal, caso1



Diferencia entre la Demanda Real y el Pronóstico de la red neuronal, caso1




Diferencia entre la Demanda Real y el Pronóstico de la red neuronal, caso1




ANEXO 6

Diferencia entre el valor de demanda real y demanda pronosticada, caso2, período
01-01-2010- a 24-05-2013.


Diferencia entre la Demanda Real y el Pronóstico de red neuronal, caso 2



Diferencia entre la Demanda Real y el Pronóstico de red neuronal, caso 2




Diferencia entre la Demanda Real y el Pronóstico de red neuronal, caso 2




ANEXO 7

Gráfica comparativa de la demanda real y los valores de pronóstico de la red neuronal periodo 01-ene-2010 a 24-may-2013, caso1.


Demanda eléctrica real vs Demanda pronosticada, caso 1




Demanda eléctrica real vs Demanda pronosticada, caso 1



Demanda eléctrica real vs Demanda pronosticada, caso 1




Demanda eléctrica real vs Demanda pronosticada, caso 1




ANEXO 8

Gráfica comparativa de la demanda real y los valores de pronóstico de la red neuronal periodo 01-ene-2010 a 24-may-2013, caso2.


Demanda eléctrica Real vs Demanda Pronósticada, caso 2



Demanda eléctrica Real vs Demanda Pronósticada, caso 2



Demanda eléctrica Real vs Demanda Pronósticada, caso 2



Demanda eléctrica Real vs Demanda Pronósticada, caso 2

