



UNIVERSIDAD AUTÓNOMA DEL ESTADO DE MÉXICO

CENTRO UNIVERSITARIO UAEM ECATEPEC

TÍTULO DEL TRABAJO:

**Diseño y entrenamiento de una red neuronal para la estimación
de daño en una estructura escolar bajo vibraciones**

T E S I S

**QUE PARA OBTENER EL GRADO DE
MAESTRO EN CIENCIAS DE LA COMPUTACIÓN**

P R E S E N T A

ING. ROBERTO CARLOS VALDÉS GARCÍA

ASESOR:

Dra. en I. de. S. TERESA IVONNE CONTRERAS TROYA

Revisores:

**Dr. en C. RODOLFO ZOLA GARCÍA LOZANO
M. en C. JESÚS BARRÓN VIDALES**

Ecatepec de Morelos, Estado de México (OCTUBRE 2019)

I. Resumen

En este trabajo de investigación se realizó el análisis de las estructuras escolares U170 y U270, siendo un edificio de un piso con espacio para dos aulas y con dos niveles, ocho aulas y un espacio intermedio donde están las escalas respectivamente. Se realizaron estudios estáticos para conocer el Factor de seguridad (FD), que es un parámetro que brinda SolidWorks y estudios de vibración que imitan el movimiento sísmico para identificar el comportamiento y resistencia de la estructura ante un evento de este tipo. Por otra parte, se diseñó y entrenó una red neuronal artificial utilizando Matlab con los resultados de las simulaciones para predecir un resultado similar al que se obtuvo en la simulación. Así mismo, se propuso un diseño de una interfaz gráfica para la red pueda ser usada de manera simple.

II. Abstract

In this research work it was made the analysis of the U170 and U270 school structures, being a one-level building with space for two classrooms and with two levels, eight classrooms and an intermediate space where the stairs are, respectively. Static studies were made to know the Safety Factor (FD), which is a parameter provided by SolidWorks and vibration studies that mimic the seismic movement to identify the behavior and resistance of the structure to an event of this type. On the other hand, an artificial neural network was designed and trained using Matlab with the results of the simulations to predict a result similar to that obtained in the simulation. Likewise, a design of a graphic interface for the network could be used in a simple way.

Índice

I. Resumen.....	VII
II. Abstract.....	VII
III. Introducción	1
IV. Hipótesis.....	3
V. Objetivos	3
Objetivo General.....	3
Objetivos Particulares	4
VI. Metodología	4
Capítulo 1 Marco teórico	5
1.1 Análisis de estructuras.....	5
1.1.1 Diseño estructural	5
1.1.2 Análisis sísmico	7
1.1.3 Modelos estructurales	12
1.2 Estructuras escolares tipo U170 y U270	14
1.2.1 Estructura tipo U170.....	14
1.2.2 Estructura tipo U270.....	15
1.3 Software para diseño y simulación estructural	18
1.3.1 SolidWorks	18
1.4 Redes Neuronales Artificiales (RNAs)	19
1.4.1 Neurona artificial	20
1.4.2 Estructura de una red	21
1.4.3 Funcionamiento de las RNAs	22
1.4.3.1 Entrenamiento	23
1.4.3.1.1 Entrenamiento supervisado	24
1.4.3.1.2 Entrenamiento no supervisado	25
1.4.3.2 Perceptrón	26
1.4.3.2 Backpropagation	27
1.5 Estado del arte	30
Capítulo 2 Desarrollo “Simulación y RNAs”	41
2.1 Metodología aplicada	41

2.2 Funcionalidad	41
2.3 Modelado 3D y simulación	41
2.3.1 Construcción de los modelos 3D del edificio U170 y U270.....	43
2.3.2 Simulación de fuerzas sobre el modelo de un piso	44
2.3.2.1 Configuración utilizada en SolidWorks	44
2.4 Creación de la base de datos.....	52
2.4.1 Aumentos entre frecuencias y desplazamientos.....	53
2.4.2 Extracción de los datos para la base de datos	54
2.5 Creación de las redes neuronales (RNs).....	56
2.5.1 Diseño de la RN para los modelos U170 y U270	56
2.5.2 Preprocesamiento de los datos	57
2.5.2.1 Variables dummies	57
2.5.3 Redes entrenadas usando Matlab	58
2.5.3.1 ToolBox de Matlab.....	59
Capítulo 3 Resultados	64
3.1 Resultados de la simulación en SolidWorks.....	64
3.1.1 Tensión Von Mises	64
3.1.2 Desplazamiento.....	67
3.1.3 Distribución del factor de seguridad (FDS)	69
3.2 Resultados de las redes neuronales desarrolladas.....	71
3.2.1 Redes entrenadas usando MATLAB	72
3.2.1.1 Redes para el U170	72
3.2.1.2 Redes para el U270	93
3.2.2 Redes entrenadas usando Python	114
3.2.2.1 Redes Python para el U170	114
3.2.2.2 Redes Python para el U270	120
3.2.3 Interfaz en Matlab para uso de la RN	125
Conclusiones.....	126
Trabajo futuro	129

Índice de Figuras

Figura 1. Placas tectónicas de México.....	1
Figura 2. Diagrama de metodología de prototipos	4
Figura 3. Zonas sísmicas de la República Mexicana	10
Figura 4. Número de simuladores sísmicos	11
Figura 5. Vista lateral U170	15
Figura 6. Vista frontal U170.....	15
Figura 7. Vista lateral U270	16
Figura 8. Vista frontal U270 (mitad izquierda)	17
Figura 9. Fotografía de escuela con modelo U270	17
Figura 10. Imagen de un modelo de la red neuronal	20
Figura 11. Esquema de una neurona.....	21
Figura 12. Estructura de una red.....	21
Figura 13. Red neuronal de doble capa	23
Figura 14. Aprendizaje supervisado	25
Figura 15. Aprendizaje no supervisado	25
Figura 16. Arquitectura del modelo Perceptrón	26
Figura 17. Ejemplo de RN con Backpropagation	28
Figura 18. Modelos de elementos finitos de la Catedral y el Sagrario de la ciudad de México	33
Figura 19. Mecanismo de colapso de la fachada de una iglesia típica den Oaxaca donde	33
Figura 20. Índice de vulnerabilidad.....	34
Figura 21. Parámetros de vulnerabilidad	35
Figura 22. Función de vulnerabilidad para una aceleración de 0.21 g.....	36
Figura 23. Modelo 3D de un rin de aleación AlSi7Mg	39
Figura 24. Perfiles base para columnas y vigas	43
Figura 25. Modelo de la estructura escolar U170.....	43
Figura 26. Modelo de la estructura escolar U270.....	44
Figura 27. Configuración de estudio dinámico en SolidWorks	45
Figura 28. Configuración de estudio estático en SolidWorks.....	46
Figura 29. Selección de materiales en SolidWorks	47
Figura 30. Selección de sujeciones U170.....	48
Figura 31. Selección de sujeciones U270.....	48
Figura 32. Excitación en la base o sujeción seleccionada	49
Figura 33. Masa distribuida en U170	50

Figura 34. Masa distribuida en U270	50
Figura 35. Malla en la estructura U170	51
Figura 36. Malla en la estructura U270	51
Figura 37. Combinación de frecuencias con desplazamientos	54
Figura 38. Impresión de pantalla “Grafica de respuesta”	54
Figura 39. Datos extraídos de la “Grafica de respuesta”	55
Figura 40. Estructura general de la red neuronal	57
Figura 41. Ventana principal del ToolBox para RNS	59
Figura 42. Ventana selección de entradas.....	60
Figura 43. Ventana selección de salidas	60
Figura 44. Ventana configuración general de la RN	61
Figura 45. Ventana estructura de la red diseñada	61
Figura 46. Ventana configuración del conjunto de entrenamiento	62
Figura 47. Ventana configuración de parámetros para entrenamiento	62
Figura 48. Ventana estado de entrenamiento de la RN.....	63
Figura 49. Ventana exportación de los resultados de la RN	63
Figura 50. Tensión Von Mises en el modelo U170	65
Figura 51. Visualización de la tensión en el modelo U170	65
Figura 52. Tensión Von Mises en el modelo U270	66
Figura 53. Visualización de la tensión en el modelo U270	66
Figura 54. Desplazamiento (mm) en el modelo U170.....	67
Figura 55. Visualización del desplazamiento (mm) en el modelo U170	67
Figura 56. Desplazamiento (mm) en el modelo U270.....	68
Figura 57. Visualización del desplazamiento (mm) en el modelo U270	68
Figura 58. Distribución del factor de seguridad en el modelo U170	70
Figura 59. Visualización del factor de seguridad en el modelo U170	70
Figura 60. Distribución del factor de seguridad en el modelo U270	71
Figura 61. Visualización del factor de seguridad en el modelo U270	71
Figura 62. Simbología de los resultados.....	73
Figura 63. T1 Br 22-10n U170	74
Figura 64. D1 Br 22-10n U170.....	74
Figura 65. T2 Br 22-10n U170	75
Figura 66. D2 Br 22-10n U170.....	75
Figura 67. FDS Br 22-10n U170	75

Figura 68. Porcentaje de error T1	76
Figura 69. Porcentaje de error D1	76
Figura 70. Porcentaje de error T2.....	76
Figura 71. Porcentaje de error D2	76
Figura 72. Porcentaje de error FDS	76
Figura 73. Simulación de T1	77
Figura 74. Simulación de D1.....	77
Figura 75. Simulación de T2	77
Figura 76. Simulación de D2.....	77
Figura 77. Simulación de FDS	78
Figura 78. Posicionamiento de salidas en figuras.....	78
Figura 79. Resultados Net BR 22n U170	79
Figura 80. Resultados Net BR 11-5n U170.....	80
Figura 81. Resultados Net LM 22-10n U170	81
Figura 82. Resultados Net LM 44n U170.....	82
Figura 83. Resultados Net LM 11-5n U170	83
Figura 84. Resultados Net LM 11-11-5n U170	84
Figura 85. Resultados Net BR 11n U170	85
Figura 86. Resultados Net LM 22n U170.....	86
Figura 87. Resultados Net BR 44n U170	87
Figura 88. Resultados Net LM 11n U170.....	88
Figura 89. Resultados Net LM 22-11-5n Pureline U170.....	89
Figura 90. Resultados Net BR 22-11-5n Pureline U170	90
Figura 91. Resultados Net BR 22n Salidas separadas U170	92
Figura 92. Comparación de MSE de las mejores redes U170	93
Figura 93. Comparación de R de las mejores redes U170.....	93
Figura 94 Performance red Br 44n U270.	94
Figura 95. Regresión red Br 44n U270.....	95
Figura 96. Resultados Net Br 44n U270.....	96
Figura 97. Error cuadrático Net Br 44n U270	97
Figura 98. Porcentaje de error Net Br 44n U270.....	98
Figura 99. Simulación T1 red Br 44n U270	98
Figura 100. Simulación D1 red Br 44n U270.....	98
Figura 101. Simulación T2 red Br 44n U270	99

Figura 102. Simulación D2 red Br 44n U270.....	99
Figura 103. Simulación FDS red Br 44n U270	99
Figura 104. Resultados Net Lm 22-10n U270.....	100
Figura 105. Resultados Net Br 11-5n U270	101
Figura 106. Resultados Net Br 22n U270.....	102
Figura 107. Resultados Net Lm 44n U270	103
Figura 108. Resultados Net Lm 11-5n U270.....	104
Figura 109. Resultados Net Lm 11-11-5n U270	105
Figura 110. Resultados Net Lm 22n U270	106
Figura 111. Resultados Net Br 22-10 U270	107
Figura 112. Resultados Net BR 11n U270	108
Figura 113. Resultados Net Lm 11 U270	109
Figura 114. Resultados Net Lm 22-11-5n PURELINE U270	110
Figura 115. Resultados Net Br 22-11-5n PURELINE U270.....	111
Figura 116. Comparación de MSE U270	113
Figura 117. Comparación de R U270.....	113
Figura 118. T1 Net Br 22n salidas separadas U270	113
Figura 119. D1 Net Br 22n salidas separadas U270	113
Figura 120. T2 Net Br 22n salidas separadas U270	114
Figura 121. D2 Net Br 22n salidas separadas U270.....	114
Figura 122. FDS Net Br 22n salidas separadas U270.....	114
Figura 123. Performance Net 22n GD U170.....	115
Figura 124. Red 22n GD Python U170	116
Figura 125. Simulación red 22n GD U170.....	117
Figura 126. Performance de las redes 22n GD con salidas separadas U170	117
Figura 127. Red 22n GD Python salidas separadas U170	118
Figura 128. Simulación de Red 22n GD Python salidas separadas U170	119
Figura 129. Performance Net 22n GD U270.....	120
Figura 130. Red 22n GD Python U270	121
Figura 131. Simulación red 22n GD U270.....	122
Figura 132. Performance de Redes 22n GD Python salidas separadas U270.....	122
Figura 133. Red 22n GD Python salidas separadas U270	123
Figura 134. Simulación Red 22n GD Python salidas separadas U270.....	124
Figura 135. Interfaz de usuario.....	125

Índice de Tablas

Tabla 1. Ventajas y desventajas del acero	8
Tabla 2. Tipos de suelo.....	9
Tabla 3. Valores de T_a , T_b y r	9
Tabla 4. Valores por tipo de suelo y zonas de la República Mexicana.....	10
Tabla 5. Variables sísmicas fundamentales	13
Tabla 6. Geometría de estructura tipo U170.....	14
Tabla 7. Geometría de estructura tipo U270.....	16
Tabla 8. Matriz de probabilidad de daño para una aceleración de 0.21g.....	36
Tabla 9. Propiedades mecánicas del rin de aleación AlSi7Mg.....	38
Tabla 10. Variables de entrada/salida atenuación sísmica.....	40
Tabla 11. Metodología utilizada.....	42
Tabla 12. Entradas para la red U170	52
Tabla 13. Entradas para la red U270	52
Tabla 14. Salidas para las redes del U170 y U270	53
Tabla 15. Lista de materiales.....	53
Tabla 16. Ejemplo de extracción de datos.....	55
Tabla 17. Propuesta de arquitectura de RNs para pruebas.....	56
Tabla 18. Ejemplo de variables Dummies	58
Tabla 19. Error cuadrático y coeficiente de correlación U170	73
Tabla 20. MSE y Coeficiente de correlación Net BR 22n Salidas separadas U170	91
Tabla 21. Comparación de MSE y Coeficiente de Correlación U170	91
Tabla 22 MSE y Coeficientes de correlación de las redes del U270	94
Tabla 23. MSE y R Net BR 22n Salidas separadas U170	112
Tabla 24. Comparación de MSE y r entre red con salidas separadas y la BR 44 del U270.....	112
Tabla 25. Redes en Python U170	115
Tabla 26 . Redes en Python U270	120



III. Introducción

Los sismos son sacudidas en la corteza terrestre que se producen debido a la liberación de energía acumulada, cuando la corteza terrestre se rompe, produciendo vibraciones que se distribuyen en todas las direcciones. Estos han ocurrido desde hace millones de años y afectan a todo el mundo. Hasta la fecha no hay una manera de saber con exactitud cuándo y en dónde se presentará un sismo, de manera que países del primer mundo aplican nuevos métodos en la construcción de estructuras para que logren resistir el movimiento generado por los sismos, con la finalidad de recibir la menor cantidad de daño posible y aún más importante, evitar pérdidas humanas [1].

Los sismos dependen del movimiento de las placas tectónicas y México está situado donde convergen las Placas Cocos, Rivera y la Placa del Caribe, las cuales están en continuo movimiento (fig. 1), debido a esto se producen constantes sismos en las diferentes zonas de la República Mexicana.

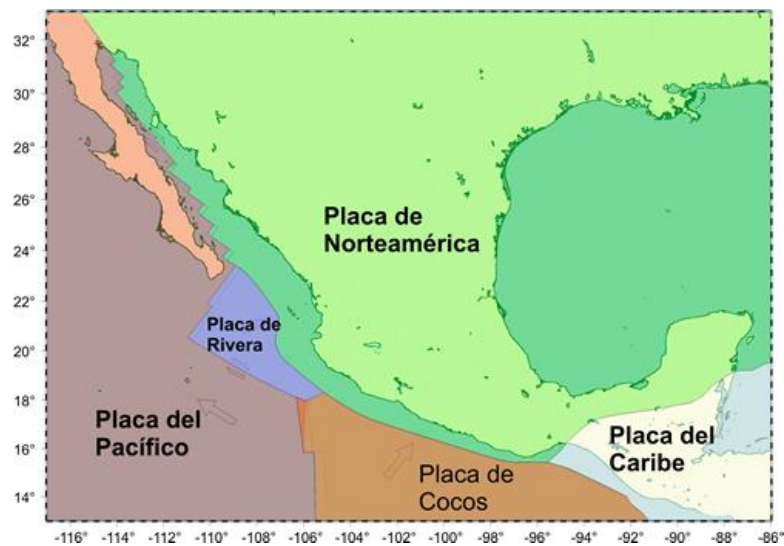


Figura 1. Placas tectónicas de México

Obtenida en: <https://www.sgm.gob.mx/Web/MuseoVirtual/imagenes/riesgos/mapa.png>

La Ciudad de México, aunque no se encuentre sobre la costa, es uno de las zonas de mayor actividad sísmica, debido a que se localiza lo suficientemente cerca para recibir los efectos, la causa





de que estos sismos sean más peligrosos en esta zona es la naturaleza de su terreno ya que fue construida en lo que fue un lago [2].

Entre los sismos más fuertes en México, se destacan los sismos del 57 y 85. El 28 de julio de 1957, se registró un sismo que tuvo una magnitud de 7.5 grados, el epicentro se localizó a 100 km al sureste de Acapulco, a una profundidad de 25 km., entre los daños que causó en la Ciudad de México está la caída del Ángel de la Independencia y un edificio de la Escuela Superior de Ingeniería y Arquitectura del IPN [3]. El jueves 19 de septiembre de 1985 ocurrió un sismo de una magnitud de 8.1, que fue originado en la brecha de Michoacán, en las costas del Pacífico, los daños materiales (muchas de las construcciones que colapsaron eran relativamente nuevas) y víctimas (se desconoce el número total de víctimas, tampoco se conoce el número de personas afectadas por el desastre, entre damnificados y quienes sufrieron secuelas psicológicas) se produjeron en tres delegaciones: Cuauhtémoc, Venustiano Carranza y Gustavo A. Madero [4].

En septiembre de 2017 México sufrió dos sismos de gran magnitud. El primero se registró la noche del 7 de septiembre a las 23:49 horas, con una magnitud de 8.2 informó el Servicio Sismológico Nacional. Este fue el movimiento telúrico más intenso que se ha tenido en el país luego del vivido en 1985 [5][6]. El segundo ocurrió el 19 de septiembre, a las 13:14 horas, con magnitud 7.1, este sismo colapsó 44 edificios (incluyendo varias escuelas) con un saldo de 117 muertos, el traslado de 699 personas a diversos hospitales y 201 que no han sido localizadas según [7][8].

Hoy en día existe el Sistema de Alerta Sísmica Mexicano (SASMEX) que surgió a partir del terremoto de 1985 como un método preventivo en caso de sismos fuertes, éste es operado por el Centro de Instrumentación y Registro Sísmico A.S. (CIRES), su función principal es advertir de manera anticipada cuando algún sismo que ya ocurrió se calcula fuerte y puede causar daños, el cálculo de la estimación de la magnitud del sismo es en segundos, si éste es de magnitud mayor a 4.0 grados la información se publica en aproximadamente 5 minutos [9][10]. La red sismológica nacional actualmente cuenta con cerca de 102 equipos para el registro de sismos que están organizados en diferentes subredes: Red sismológica de banda ancha, Red sismos del Valle de México, Red sísmica del volcán Tacaná y la Red sismológica Convencional [11].





Con las pérdidas humanas y materiales que provocaron los últimos sismos del 7 y 19 de septiembre del 2017, se tiene que la alerta sísmica como método preventivo no es 100% efectiva y surge la necesidad de otras herramientas que sean un complemento, por ejemplo, que se pueda tener conocimiento de las estructuras que son un riesgo, ya sea por un mal diseño, la ubicación o por la edad del mismo, para que las autoridades u organizaciones correspondientes tomen las medidas apropiadas (una restauración y reforzamiento o simplemente una demolición).

Con el uso de la inteligencia artificial en este trabajo se plantea el desarrollo de una red neuronal que sea capaz de estimar la resistencia de las estructuras ante sismos, los resultados de la misma serán interpretados para tomar la decisión de si la estructura analizada está en riesgo de colapsar. Se propone utilizar la estructura de las escuelas públicas (tomando en cuenta que en muchas de ellas no cuentan con la organización óptima para reaccionar ante un desastre natural, por ejemplo, la coordinación necesaria para evacuar en caso de sismos) por lo que se eligieron los edificios U170 y U270 del catálogo de la SEP, su diseño brinda la ventaja de ser muy similares entre sí desde nivel primaria hasta medio superior, por lo cual, la red neuronal podría funcionar para varias estructuras de diferentes niveles educativos.

IV. Hipótesis

Una red neuronal artificial será capaz de obtener las tensiones, desplazamientos y el factor de seguridad con exactitud de una estructura escolar a partir de los datos generados por simulaciones.

V. Objetivos

Objetivo General

Diseñar, entrenar y probar una red neuronal que sea capaz de predecir la tensión, desplazamiento y factor de seguridad de una estructura escolar bajo vibraciones.





Objetivos Particulares

1. Modelar un edificio de un piso en 3D basado en una estructura escolar U170 utilizando SolidWorks.
2. Modelar un edificio de dos pisos en 3D basado en una estructura escolar U270 utilizando SolidWorks.
3. Utilizar SolidWorks para simular vibraciones a los modelos U170 y U270 3D diseñados previamente.
4. Identificar las zonas más vulnerables y la resistencia general de las estructuras.
5. Diseñar, entrenar y probar una red neuronal utilizando Matlab para el comportamiento los edificios tipo U170 y U270.
6. Diseñar una interfaz en Matlab para utilizar las redes neuronales de una manera que sea fácil interpretar los resultados.

VI. Metodología

Se utiliza la metodología de prototipos (fig. 2) debido a que permite diseñar y desarrollar modelos, los cuales pueden ser escalables o bien ser utilizados como guía ya sea para realizar uno nuevo aún más complejo o para descartar diseños que son poco eficientes.

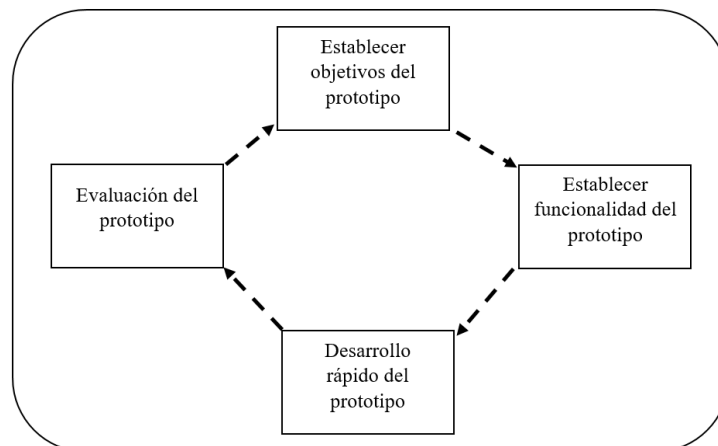


Figura 2. Diagrama de metodología de prototipos

Elaboración propia con base en: <http://eccianalisis.blogspot.mx/2013/05/modelo-de-construccion-de-prototipos.html>





Capítulo 1 Marco teórico

1.1 Análisis de estructuras

Desde hace varios años se buscan diferentes maneras para construir edificios capaces de soportar los movimientos que generan los sismos. Primero se utilizaron aisladores de base, lo cual tenía como objetivo la colocación de una capa intermedia entre el edificio y el terreno. Esta técnica tiene cierto grado de eficiencia, pero depende de las características de la excitación de la estructura. En la ingeniería estructural los sistemas de control han tomado fuerza, éstos no se enfocan en el aislamiento de la estructura, sino en limitar la respuesta por medio de dispositivos estratégicamente colocados en las estructuras. Los sistemas activos pueden ejercer fuerzas sobre las estructuras de empuje y de jale, su principal desventaja es el excesivo uso de energía que puede no estar disponible en el momento de un sismo. Los sistemas semiactivos son menos eficientes, estos utilizan características de los activos y pasivos, estos sistemas se oponen al movimiento de la estructura de forma variable, de tal modo lo hace estable y la energía requerida puede ser suministrada por una batería de baja potencia [12].

Para la construcción de edificios los ingenieros comúnmente utilizan el método de esfuerzos permisibles (ASD), aunque están migrando al diseño por factores de carga y resistencia (LRFD) ya que al parecer LRFD presenta algunas ventajas debido a que contempla al diseño plástico y al diseño límite también conocido como diseño por colapso [12].

1.1.1 Diseño estructural [13]

El diseño de estructuras engloba un conjunto de actividades que desarrolla el líder del proyecto para determinar la forma, dimensiones y características que tendrá la estructura. El objetivo es diseñar un sistema capaz de resistir las fuerzas a las que podría estar sometido sin colapsar o tener un comportamiento no deseado.

Para la construcción de un sistema estructural se debe pasar por las siguientes etapas:





- Estructuración: en esta etapa del proceso se establecen los materiales base de la estructura y la forma general de ésta, así como la distribución de sus componentes, dimensiones y características más importantes.
- Análisis: Aquí se encuentran las actividades que dan respuesta al comportamiento de la estructura bajo fuerzas exteriores que puedan afectarla, se determinan los efectos de las cargas que afectan al sistema durante su tiempo de vida útil. Para esto es necesario contar con diferentes modelos estructurales (ver sección 1.1.3).
- Dimensionamiento: Esta etapa define en detalle las dimensiones de la estructura y se evalúan los requerimientos de seguridad, se elaboran los planos y especificaciones para la construcción de la estructura.

Estado límite

El edificio debe contar con el sistema estructural que tenga un flujo correcto de las diferentes fuerzas que generan las diferentes cargas, para que éstas sean transmitidas de forma continua a la cimentación. De igual manera, se debe tener la cimentación que permita la transmisión de las fuerzas al subsuelo. Es importante que las estructuras cumplan con lo siguiente:

- Contar con la seguridad apropiada contra la aparición de estados de límite de falla posibles por la combinación de las cargas que están presentes.
- No sobrepasar ningún estado límite de servicio que no vayan acorde al correcto funcionamiento de la estructura.

El estado límite de falla es cualquier escenario que corresponda al agotamiento de la capacidad de carga de la estructura o de cualquiera de sus componentes como la cimentación o daños que afecten directamente a su resistencia.

Estado límite de servicio es la aparición de desplazamientos, grietas, vibraciones o daños que afectan el funcionamiento de la estructura, pero no perjudican la capacidad para soportar cargas.





Las cargas también conocidas como acciones que se toman en cuenta en el diseño de una estructura son tres: cargas permanentes, variables y accidentales.

- **Cargas permanentes:** éstas se ejercen de forma continua sobre la estructura y su intensidad no varía mucho con el tiempo. Entre dichas cargas se encuentran las cargas muertas (peso propio de la estructura), el empuje elástico de suelos y de líquidos; los desplazamientos y las deformaciones de la estructura que cambian poco con el tiempo.
- **Cargas variables:** estas cargas cambian de manera significativa con el tiempo, las principales son las cargas vivas (personas), la temperatura, las deformaciones y hundimientos que no son constantes, de igual manera entran los efectos dinámicos.
- **Cargas accidentales:** estas cargas no son propias del correcto funcionamiento de la estructura, y su intensidad puede variar bruscamente por breves lapsos, aquí se encuentran los eventos sísmicos, los efectos del viento, cargas por granizo, explosiones, incendios y otros fenómenos inesperados.

Resistencia del diseño

Para que la estructura sea capaz de soportar dichas cargas se toma en cuenta la resistencia del diseño el cual es la resistencia a una acción o carga o una combinación de ellas que podría provocar algún estado límite. La resistencia se calcula con procedimientos analíticos basados en resultados teóricos y experimentales (ver sección 2.1.3). En la tabla 1 se muestran las ventajas y desventajas el uso de acero en la construcción de estructuras.

1.1.2 Análisis sísmico

Es fundamental el análisis sísmico, ya que permite conocer las fuerzas que ejerce un sismo sobre la estructura. La sección 3 de las Normas Técnicas Complementarias para Diseño por Sismo (NTDS) marca el espectro de aceleraciones α que deben adoptarse cuando se use el análisis dinámico. La aceleración de la gravedad α está dada por:





$$a = \begin{cases} \left(1 + \frac{3T}{T_a}\right)^{\frac{c}{4}} & \text{si } T \text{ es menor que } T_a \\ c & \text{si } T \text{ está entre } T_a \text{ y } T_b \\ qc & \text{si } T \text{ excede a } T_b \end{cases} \quad (1)$$

Acero estructural	
Ventajas	Desventajas
Resistencia. Cuenta con una alta resistencia por unidad de peso, que significa un peso bajo en general de toda la estructura, esto es importante en puentes con claros grandes y en edificios altos o en estructuras con cimentaciones deficientes	Costo de mantenimiento. La mayoría de los aceros no dejan de ser susceptibles a la corrosión al estar expuesto al agua y al aire, por lo que debe de pintarse constantemente.
Elasticidad. El acero es el que tiene un comportamiento más cercano a la teoría que otros materiales. Los momentos de inercia de la estructura de acero pueden ser calculados con precisión en comparación con estructura de concreto reforzado	Costo de protección contra fuego. Aunque los elementos no son flamables, la resistencia del acero se reduce cuando es expuesto a altas temperaturas además que el acero es un conductor de calor, de manera que se puede extender la temperatura de un punto a otro. Esto provoca que deban usarse aislantes para aumentar la seguridad.
Durabilidad. La duración de las estructuras de acero puede ser indefinidas si se le da el correcto mantenimiento, algunas investigaciones muestran que con ciertas condiciones no se necesita mantenimiento alguno a base de pintura.	Pandeo. Esta deformación se presenta en los elementos estructurales entre más largos y delgados sean. Al utilizarse como columnas, debe utilizar mucho material para evitar el pandeo.
Ductilidad. Esta propiedad permite a un material soportar grandes deformaciones sin fallar a los esfuerzos de tensión. Cuando elementos estructurales son sometidos a cargas normales se generan esfuerzos en varios puntos, la ductilidad de los aceros comunes les permite fluir en esos puntos así evitando fallas prematuras.	Fatiga. Entre las ventajas se habló anteriormente de la gran resistencia del acero, pero esta puede ser reducida con un gran número de cargas, o cambios agresivos en la tensión.
Uniformidad. Esta propiedad permite a las otras no tengan cambios significativos con el tiempo, cosa que no ocurre con el concreto reforzado.	Fracturas. En ciertas condiciones como bajas temperaturas el acero pierde su ductilidad y presentar fracturas.
Tenacidad. La tenacidad en los aceros indica su resistencia y ductilidad. Un elemento de acero cargado hasta deformarse es capaz de resistir grandes fuerzas. Esta es una característica importante ya que indica que los elementos pueden ser deformados durante la construcción sin presentar fracturas. En otras palabras, la tenacidad es la capacidad de absorber energía.	
Ampliaciones. Las estructuras de acero permiten realizar apilamientos sin gran complicación.	
Otras. Entre otras ventajas que presenta el acero estructural se encuentran la facilidad de unir diversos calibres, realizar conexiones con soldadura, el uso de tornillos y remaches, realizar estructuras prefabricadas bajo diseño y la posibilidad de reutilizar material.	

Tabla 1. Ventajas y desventajas del acero
 Elaboración propia, basada en [12].





Donde T , T_a y T_b se expresan en segundo, c es un coeficiente sísmico y es el más importante de la acción sísmica que se emplea para el análisis estático y dinámico. Este coeficiente es una cantidad adimensional que establece la fuerza constante horizontal que se ejerce en la base de la estructura como una fracción del peso total de la misma [14].

La ciudad de México se divide en diferentes zonas por el tipo de suelo (tabla 2).

Zona	Descripción
Lomas (I)	Suelos formados por rocas o considerados en general firmes. Superficies intercaladas, depósitos arenosos.
Transición (II)	Depósitos profundos que se encuentran a 20 m. Con estratos arenosos e intercalados con capa de arcilla lacustre con espesores variables de centímetros a metros.
Lacustre (III)	Constituida por depósitos de arcilla altamente compresible, separados por capas arenosas con contenidos diversos. Estas capas son firmes, duras y con varios espesores

Tabla 2. Tipos de suelo
Elaboración propia basada en: [12]

En la tabla 3 se observan los Valores de T_a , T_b y r según las zonas de la tabla de 2.

Zona	T_a	T_b	r
I	0.2	0.6	$1/2$
II	0.3	1.5	$2/3$
II	0.6	3.9	1.0

Tabla 3. Valores de T_a , T_b y r
Elaboración propia basada en: [12]

En la figura 3 se especifican las zonas (A, B, C y D) en las cuales se divide la República Mexicana por nivel de intensidad de los sismos. Donde en A son los sismos de intensidad ligera y D la mayor intensidad. En la Tabla 4 se enlistan los valores para realizar los cálculos para el análisis sísmico dependiendo de la zona y el tipo de tierra.





Zona sísmica de la República Mexicana	Tipo de suelo	a_0	C	$T_a(S)$	$T_b(S)$	r
Zona A	I (Terreno firme)	0.02	0.08	0.2	0.6	0.5
	II (Terreno de transición)	0.04	0.16	0.3	1.5	2/3
	III (Terreno compresible)	0.05	0.2	0.6	2.5	1
Zona B	I (Terreno firme)	0.04	0.14	0.2	0.6	1/2
	II (Terreno de transición)	0.08	0.3	0.3	1.5	2/3
	III (Terreno compresible)	0.1	0.36	0.6	2.9	1
Zona C	I (Terreno firme)	0.36	0.36	0	0.6	1/2
	II (Terreno de transición)	0.64	0.64	0	1.4	2/3
	III (Terreno compresible)	0.64	0.64	0	1.9	1
Zona D	I (Terreno firme)	0.50	0.50	0	0.6	0.5
	II (Terreno de transición)	0.86	0.86	0	1.2	2/3
	III (Terreno compresible)	0.86	0.86	0	1.7	1

Tabla 4. Valores por tipo de suelo y zonas de la República Mexicana
 Elaboración propia basada en: [12]

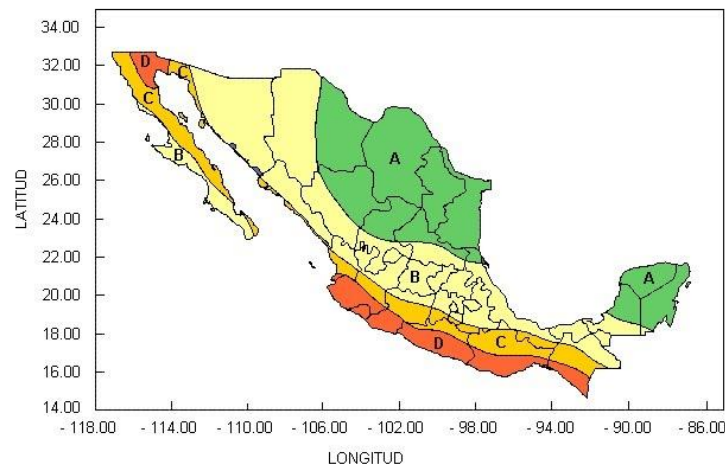


Figura 3. Zonas sísmicas de la República Mexicana

Obtenida en: https://sites.google.com/site/microzonecct/_/rsrc/1308002596260/principal/metodologia/Figura%204-2-1.jpg





Simuladores sísmicos

Cada año se registra mundialmente un promedio de un sismo con una magnitud de 8 o superior y aproximadamente 17 sismos de entre 7.0 y 7.9. La fuerza de estos sismos excede las capacidades de algunas estructuras ya sea porque están en una mala ubicación, tienen deterioro o están mal diseñados. Debido a esto miles de personas han fallecido por estos colapsos [15]. Estos desastres dieron inicio a la ingeniería sísmica en el mundo, que tiene como objetivo probar, observar y analizar los efectos de los sismos en estructuras reales y a escala para estimar la capacidad de los elementos estructuras, con el fin de mejorar el diseño de las construcciones [16].

Hoy en día las mesas vibratorias tienen la aproximación más real a los movimientos de un sismo. Estos simuladores se han desarrollado principalmente en Estados Unidos y Japón (fig. 4), experimentando con capacidades de carga de miles de toneladas [17].




Figura 4. Número de simuladores sísmicos
Fuente: [1]





1.1.3 Modelos estructurales [13]

Un modelo estructural puede ser definido como cualquier representación física de una estructura o una porción la misma, comúnmente el modelo es construido a una escala reducida. Hay diferentes modelos estructurales y son clasificados dependiendo su uso y el resultado que se busca:

- **Modelos elásticos:** son utilizados cuando se busca obtener resultados de elasticidad. Hay una similitud directa con el prototipo, pero se desarrollan con materiales homogéneos y elásticos que pueden no ser pertenecientes al prototipo.
- **Modelos indirectos:** son una variación de los elásticos, usadas para obtener líneas de influencia para acciones y reacciones internas como pueden ser fuerzas cortantes y fuerzas axiales.
- **Modelos directos:** tienen una similitud geométrica con el prototipo en todos los aspectos y las cargas son aplicadas de la misma forma que al prototipo.
- **Modelos de resistencia:** también conocidos como modelos reales, son hechos con materiales similares a los del prototipo con la finalidad de predecir el comportamiento del prototipo para todas las cargas aplicadas.
- **Modelos para efectos de viento:** se utilizan para clasificar la modelación bajo fuerzas originadas por el viento.
- **Modelos dinámicos:** tienen gran importancia, ya que son utilizados para estudiar los efectos que tienen las vibraciones o cargas dinámicas.
- **Otros:** se encuentran los modelos térmicos, fotomecánicos, fotoelasticidad y de procesos constructivos, estos son de gran apoyo en la planeación, diseño y construcción de estructuras complejas.

Modelación dinámica de estructuras

En la investigación estructural, los modelos dinámicos a escala reducida han demostrado ser una herramienta para generar conocimiento y entendimiento sobre el comportamiento de estructuras en situaciones complejas.





La dinámica de una estructura es controlada por el equilibrio balanceado de las fuerzas que dependen del tiempo que se ejercen sobre una estructura. Estas fuerzas están conformadas por las fuerzas de inercia (resultado de la masa local y la aceleración), las fuerzas de resistencia (están en función de la rigidez de la estructura en la dirección particular en la que el movimiento se está llevando a cabo). Por ultimo las fuerzas de amortiguamiento o disipación de la energía (relacionadas con el material y diseño de construcción). La similitud dinámica del modelo y del prototipo real está dado por la siguiente relación:

$$\left(\frac{Qt^2}{Ml}\right)_m = \left(\frac{Qt^2}{Ml}\right)_p \tag{2}$$

Utilizando el factor de escala:

$$\frac{Q_p}{Q_m} = S_Q \quad \frac{t_p}{t_m} = S_t \quad \frac{M_p}{M_m} = S_M \quad \frac{l_p}{l_m} = S_l \tag{3}$$

La relación de modelo-prototipo está dada por:

$$S_Q = \frac{S_l S_M}{S_t^2} \tag{4}$$

Variables Sísmicas Fundamentales	
Grupo	Cantidad física
Cargas	Fuerza, Q Presión, q Aceleración, a Aceleración gravitacional, g Velocidad, v Tiempo, t
Geometría	Longitud, l Desplazamiento, δ Frecuencia, ω
Propiedades del material	Módulo de elasticidad, E Esfuerzo, $j\sigma$ Deformaciones, $\epsilon\epsilon$ Relación de Poisson, ν Densidad de masa, ρ Energía, EN

Tabla 5. Variables sísmicas fundamentales
 Elaboración propia basada en [15]





1.2 Estructuras escolares tipo U170 y U270 [18]

La Secretaría de Educación Pública (SEP) presenta un catálogo de los tipos de estructuras utilizadas en las escuelas mexicanas. En dicho catálogo se describen más de 30 tipos de estructuras, algunas de ellas son solo variaciones de un mismo tipo, ya sea porque agregaron un techo a dos aguas o las vigas se separan algunos centímetros más. Las estructuras elegidas son la U170 y la U270, son estructuras de un piso y dos pisos respectivamente, ambas fueron implementadas en los años 70's. El grosor de las columnas y trabes en edificios de escuelas tienen un promedio aproximado de $45 \times 35 \text{ cm}$ y $35 \times 30 \text{ cm}$ respectivamente.

1.2.1 Estructura tipo U170

Cuenta con un solo nivel, el diseño fue implementado en 1970, la estructura base es metálica prefabricada. Tiene una distancia de 3.06 metros entre columnas y 8 metros para la trabe transversal. Este diseño puede ser encontrado en la versión de 48 m^2 y 96 m^2 que son de una y dos aulas respectivamente. En la tabla 6 se muestran las especificaciones de su geometría.

Geometría									
Niveles	Claro longitudinal	Claro transversal	Claro tscalera	Altura libre cerramiento	Nivel	Volado frontal	Volado posterior	Volado lateral	Material
1	3.06	8.00	N/A	2.50	Entrepiso	N/A	N/A	N/A	N/A
Apoyo			Sección						
			A	B	Azotea	2.25	2.25	0.60	Losa de concreto
Metálica prefabricada			0.12	0.30					

Tabla 6. Geometría de estructura tipo U170
 Elaboración propia basada en [18]

En las figuras 5 y 6 se muestran las vistas lateral y frontal respectivamente. En la fig. 5 se puede observar las distancias entre las dos columnas que es de 8 m y una altura de 2.5 m hasta el medio de la trabe transversal, ésta tiene un largo de 12.2 m dejando así un volado tanto trasero como frontal de 2.1 m . En la fig. 6 se observa solo la mitad de la vista frontal del edificio, mostrando la distancia entre las columnas que es de 3.06 m y la misma altura de 2.5 m .






Figura 5. Vista lateral U170
Elaboración propia basada en: [18].




Figura 6. Vista frontal U170
Elaboración propia basada en: [18].

1.2.2 Estructura tipo U270

Cuenta con dos niveles, el diseño se implementó en el año de 1970, tiene una estructura metálica prefabricada como base, con una distancia entre columnas de 3.06 metros, con uno de 4 metros para la escalera, el claro transversal es de 8 metros. Las columnas y las traveses son de diversos calibres. Las columnas en la parte inferior se unen a dados o cubos de concreto. En la tabla 7 se muestra la información de su geometría.





Geometría									
Niveles	Claro longitudinal	Claro transversal	Claro escalera	Altura libre cerramiento	Nivel	Volado frontal	Volado posterior	Volado lateral	Material
2	3.06	8.00	4.00	2.50	Entrepiso	2.20	0.00	0.00	Losa de concreto
Apoyo			Sección						
			A	B					
Metálica prefabricada			0.12	0.30	Azotea	2.25	2.25	0.60	Losa de concreto

Tabla 7. Geometría de estructura tipo U270
Elaboración propia basada en: [18].

En la figura 7 se observa la vista lateral del edificio tipo U270, al igual que el U170, la separación entre las columnas transversales es de 8 m, con una altura de 2.5 m tanto en el primer nivel como en el segundo, el volado del entrepiso es de 2.20m y el superior es de 2.25, en el entrepiso no hay volado posterior pero si uno superior de 2.25 m.




Figura 7. Vista lateral U270
Elaboración propia basada en: [18].

En la figura 8 se presenta la mitad izquierda de la vista frontal del diseño U270, la distancia entre cada columna sigue siendo de 3.06 m excepto en el medio del edificio, en donde se ponen a una distancia de 4 m para la escalera de acceso al segundo piso.






Figura 8. Vista frontal U270 (mitad izquierda)
Elaboración propia basada en: [18].

Se presenta el ejemplo (fig. 9) de la Escuela Secundaria Oficial No. 791 “Josefa Ortiz de Domínguez” situada en Diana Laura Riojas 30, Luis Donaldo Colosio, 55010 Ecatepec de Morelos, Méx. La cual tiene un diseño de estructura U270.



Figura 9. Fotografía de escuela con modelo U270
Fotografía propia.





1.3 Software para diseño y simulación estructural

1.3.1 SolidWorks

El modelado de sólidos en 3D es un aspecto fundamental para el desarrollo de productos y proporciona la base para el diseño, la simulación y la fabricación de cualquier pieza y ensamblaje de una amplia gama de sectores, aplicaciones y productos. SolidWorks permite agilizar el diseño para ahorrar tiempo. Las operaciones clave de modelado de sólidos en 3D de SolidWorks permiten:

- Crear modelos sólidos en 3D de cualquier pieza y ensamblaje, sin importar lo grande o complejos que sean.
- Mantener todos los modelos en 3D, dibujos en 2D y otros diseños y documentos de fabricación sincronizados gracias a la asociatividad, que realiza seguimientos y actualizaciones de forma automática.
- Hacer variaciones de los diseños rápidamente, mediante el control de los parámetros de diseño claves.
- Editar directamente el modelo con solo hacer clic y arrastrar geometría del modelo.
- Generar superficies para cualquier geometría en 3D, incluso formas estilizadas y orgánicas complejas.
- Analizar de forma instantánea el modelo en 3D para obtener cualquier propiedad de volumen y masa sólida (masa, densidad, volumen, momentos de inercia, etc.).

Con SolidWorks se puede perfeccionar el diseño y la fabricación de estructuras soldadas, marcos y bases que forman la estructura base de productos desarrollados en muchos sectores. Crear diseños con extrusiones y generar listas de cortes y listas de materiales necesarios para la fabricación [19].





1.4 Redes Neuronales Artificiales (RNAs)

El uso de sistemas inteligentes provenientes de la inteligencia artificial para resolver problemas cotidianos es una herramienta de apoyo cuando los modelos matemáticos no logran representar con exactitud el comportamiento de algún sistema. Las redes neuronales artificiales son utilizadas como mecanismo de aprendizaje en diferentes modelos computarizados [20]. Simón Haykin define a las redes neuronales como “un procesador masivamente paralelo distribuido que es propenso por naturaleza a almacenar conocimiento experimental y tenerlo disponible para uso propio” [21]. Su mecanismo es similar al cerebro por los siguientes dos aspectos:

- El conocimiento es adquirido por la red mediante un proceso llamado aprendizaje.
- El conocimiento se almacena mediante la modificación del peso sináptico de las diferentes conexiones entre las neuronas.

Las redes neuronales artificiales también se conocen como unidades de proceso, y su funcionamiento es simple. Consisten en recibir en las entradas, las salidas de las neuronas vecinas y calcular otro valor de salida, el cual es enviado a las neuronas restantes [22].

Los modelos de las RNAs se representan por tres tipos de capas, la primera capa es la de entrada, en ella se encuentran las neuronas que estarán recibiendo los valores de entrada desde el exterior de la red; la segunda capa se conoce como capa oculta, en ésta se encuentran un conjunto de neuronas para las cuales sus entradas y salidas pertenecen al mismo sistema, es decir, estas neuronas no tienen contacto con el exterior; la tercera capa es la de salida, aquí las neuronas tienen sus entradas provenientes de la segunda capa y las salidas van hacia el exterior, devolviendo los resultados. La figura 10 muestra el modelo estándar de una red neuronal.






Figura 10. Imagen de un modelo de la red neuronal
Elaboración propia basada en: [23].

1.4.1 Neurona artificial [22]

El elemento básico de la red neuronal es la neurona artificial, también llamada célula o autómata, que posee un estado interno conocido como nivel de activación, éste recibe señales que le permiten cambiar el estado. Si se denomina S al conjunto de estados posibles de la neurona, S podría ser por ejemplo $S = \{1,0\}$, siendo el 1 el estado activo y 0 el estado inactivo. S también puede tener un mayor número de valores por ejemplo $S = \{0,1,2, \dots, n\}$.

Las neuronas (fig. 11) tienen una función que permite modificar el nivel de activación a partir de las señales que reciben; a esta función se le conoce como función de transición de estado o función de activación. Las señales que reciben las neuronas pueden provenir del exterior de la red o de neuronas vecinas.

El nivel de activación de una neurona depende de las señales de entrada recibidas y de los valores o pesos sinápticos, pero no de valores de estados de activación anteriores. Para poder calcular el estado de activación se debe calcular primero el total de la entrada de la neurona (se calcula realizando la suma de todas las entradas ponderadas multiplicándolas por ciertos valores).






Figura 11. Esquema de una neurona
Elaboración propia basada en: [23].

1.4.2 Estructura de una red [22]

Se le conoce como estructura de la red o patrón de conectividad a la forma en la que las neuronas se conectan entre sí. La estructura más básica es la red multicapa que se muestra en la figura 12. El primer nivel se conforma por las neuronas de entrada, luego están las capas intermedias, conocidas como ocultas, en donde las neuronas responden a rasgos particulares que pueden aparecer en los patrones de entrada (es posible tener varios niveles ocultos); el último nivel es el de salida, las neuronas envían los resultados de toda la red




Figura 12. Estructura de una red
Elaboración propia basada en: [23].





1.4.3 Funcionamiento de las RNAs [23]

Para cada vector de entrada que es introducido a la red, cada elemento de dicho vector se destina a una neurona de entrada correspondiente. Una vez que la entrada ha sido recibida, cada neurona de la red la procesa y produce una salida que se distribuye entre las conexiones de las neuronas. Cuando la entrada ha sido propagada completamente por toda la red, se genera un vector de salida, cuyos elementos son cada uno de los valores de salida de cada neurona de la capa de salida. El modelo de la figura 13 se puede describir con la siguiente ecuación:

$$S = F(F(X \cdot W_1) \cdot W_2) \quad (5)$$

Donde $W_1 \cdot W_2$ son los pesos de la primera y segunda capa; F es la función de activación, que es idéntica para todas las neuronas; X es el vector de entrada y S es el vector de salida que genera la red. Los pesos $W_1 \cdot W_2$ son matrices de conexión entre las capas de la red, entonces es una multiplicación de matrices.

Ejemplo 1

A continuación, se resuelve el ejemplo de la red para la figura 13 que es una RN de dos capas. Donde:

$$W_1 = \begin{bmatrix} 1 & 2 & 4 \\ 3 & 2 & 1 \\ 2 & 5 & 1 \end{bmatrix} \quad W_2 = \begin{pmatrix} 2 & 3 \\ 2 & 1 \\ 1 & 2 \end{pmatrix}$$

La función de activación $F(x) = 2x$ y de entrada es el vector $x = \{-2,1,3\}$. Según la ecuación 1:

$$A = X \cdot W_1 = (-2,1,3) \cdot \begin{bmatrix} 1 & 2 & 4 \\ 3 & 2 & 1 \\ 2 & 5 & 1 \end{bmatrix} = (7,13,-4)$$

$$S = F(F(A) \cdot W_2) = (14,26,-8) \cdot \begin{pmatrix} 2 & 3 \\ 2 & 1 \\ 1 & 2 \end{pmatrix} = F((72,52)) = (144,104)$$





El resultado para esta red neuronal es el vector (144,104).




Figura 13. Red neuronal de doble capa
Elaboración propia basada en: [23].

1.4.3.1 Entrenamiento

El esquema de aprendizaje de una red es lo que determina el tipo de problemas que será capaz de resolver. Las Redes Neuronales Artificiales son sistemas que aprenden por medio de ejemplos, esto quiere decir que la capacidad que tiene una RNA para resolver problemas está directamente relacionada al tipo de ejemplos de los que dispone en su proceso de aprendizaje. Los ejemplos para el aprendizaje deben tener las siguientes características:

- Ser significativo: El número de ejemplos debe ser suficiente. Si el conjunto de ejemplos es reducido, la red no será capaz de adaptar sus pesos de manera eficaz.
- Ser representativo: Los componentes del conjunto de aprendizaje deberán ser diversos. Si el conjunto de aprendizaje más ejemplos de un tipo que el resto, la red será especialista en dichos subconjuntos de datos. Es importante que todas las regiones significativas sean representadas equitativamente en el conjunto de aprendizaje.

El proceso de aprendizaje de una RNA consiste en el cálculo de los valores exactos de los pesos para cada una de sus conexiones, que la capacita para resolver un problema de manera eficiente. El aprendizaje general consiste en ir introduciendo gradualmente los ejemplos del conjunto de entrenamiento y modificar los pesos de las conexiones siguiendo un esquema de aprendizaje





determinado. Una vez introducidos todos los ejemplos, se comprueba si se cumplió cierto criterio de convergencia, de lo contrario se repite el proceso y el conjunto de entrenamiento vuelve a ser introducido a la red. La configuración de los pesos puede ser durante el ingreso de cada ejemplo del conjunto de aprendizaje o cuando todos los ejemplos hayan sido introducidos.

El criterio de convergencia depende del tipo de red y del tipo de problema a resolver. El periodo de aprendizaje se puede finalizar mediante:

- Número fijo de ciclos: Se establece el número de veces que el conjunto de entrenamiento será introducido y una vez superado dicho número, se acepta la red resultante.
- Cuando el error descienda por debajo de la cantidad determinada: Se tiene que definir una función de error. Puede ser de patrón individual o a nivel de la totalidad del conjunto de entrenamiento. El valor propuesto debe ser un valor que pone un rango de error aceptado, el proceso de aprendizaje se detendrá cuando la red produzca un valor de error menor al ya establecido. Para el caso que la red genere un nivel de error por encima al establecido, es recomendado tener un segundo criterio de término, por ejemplo, el del número fijo de ciclos.
- Cuando la modificación de los pesos sea irrelevante: para algunos modelos se establece un esquema de aprendizaje que hace que las conexiones vayan modificándose cada vez con menor impacto. Si el proceso de aprendizaje no se detiene, llegara un momento en que no se produce un cambio en los pesos, en ese punto se finaliza el proceso de aprendizaje.

Existen tres tipos esquemas de aprendizaje, supervisado, no supervisado y aprendizaje por refuerzo. A continuación, se describen solo el supervisado y no supervisado, ya que son los más utilizados en este tipo de aplicación.

1.4.3.1.1 Entrenamiento supervisado

Los datos del conjunto de aprendizaje tienen dos atributos, los datos propiamente dichos, y cierta información relativa a la solución del problema. Por ejemplo, si se diseña una RNA para clasificar





un conjunto de datos en este caso un sistema para clasificar frutas, los ejemplos tendrán los datos de la fruta, e información de la solución y de qué fruta se trata. El funcionamiento del esquema de aprendizaje supervisado que se muestra en la figura 13 consiste en modificar los pesos cada vez que un ejemplo es introducido y es procesado para obtener la salida, dicha salida se comparará con el resultado que debería producirse. Para este entrenamiento se dice que hay un maestro externo el cual determina si la red funciona de manera adecuada, comparando la salida producida y la esperada.




Figura 14. Aprendizaje supervisado
Elaboración propia.

1.4.3.1.2 Entrenamiento no supervisado

En este entrenamiento, el conjunto de aprendizaje solo tiene información de los ejemplos, y no hay algo que sirva como guía para el proceso en el cual la red aprende la información. No hay un maestro que guie el aprendizaje. En la Figura 14 se tiene un diagrama general de este tipo de entrenamiento.

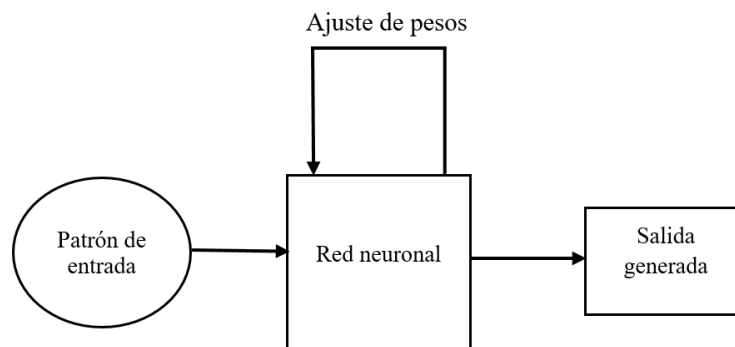


Figura 15. Aprendizaje no supervisado
Elaboración propia basada en: [23]





1.4.3.2 Perceptrón [22]

En los años 50 surgió el modelo Perceptrón, este modelo se desarrolló para que fuera capaz de realizar tareas de clasificación de manera automática. Tomaba ejemplos de diferentes clases, deseando que determinara las ecuaciones de las superficies que hacían de límite de dichas clases. Los ejemplos proveían los patrones de entrenamiento, que aportaban la información necesaria para que el sistema construyera las superficies discriminantes. Al final debía ser capaz de determinar para cualquier ejemplo nuevo, a qué clase pertenecía.

La arquitectura de esta red es simple. Cuenta con una sola capa en la que hay un conjunto de entradas, éstas pueden ser las entradas necesarias dependiendo del problema; teniendo una o más salidas. Cada una de las neuronas de entrada tienen conexión con las neuronas de salida.




Figura 16. Arquitectura del modelo Perceptrón
Elaboración propia basada en: [22]

En la figura 16 se muestra el modelo del Perceptrón, donde x_1, x_2, \dots, x_n son entradas y la salida es y ; w_1, w_2, \dots, w_n son los pesos entre las conexiones. Hay un parámetro extra, conocido como umbral denotado por θ , este umbral se usa como factor de comparación para generar la salida y éstos estarán en la misma cantidad al número de salidas.





La salida de este modelo se calcula con la activación de la neurona de salida mediante la suma de los pesos multiplicados por las entradas:

$$y' = \sum_{i=1}^n w_i x_i \quad (6)$$

El Perceptrón de una capa perdió popularidad porque no era capaz de resolver el problema XOR, el cual se corrigió con el Perceptrón multicapa.

1.4.3.2 Backpropagation [23]

El entrenamiento o aprendizaje de la red es la manera en la cual se modifican los parámetros de la misma, dicha modificación se hace para que la salida generada, sea lo más cercana posible a la salida real del sistema analizado. Por lo tanto, para cada entrada es necesario una salida deseada. El aprendizaje de la red se observa como un problema de minimización:

$$\text{Min}_w E \quad (7)$$

Siendo W el conjunto de los parámetros de la red (pesos y umbrales); E es una función de error que evalúa la diferencia entre la salida generada por la red y la salida real deseada. Este error se puede definir como:

$$E = \frac{1}{2} \sum_{n=1}^N e(n) \quad (8)$$

N es el número de patrones o datos y $e(n)$ es el error generado por la red correspondiente al patrón n , dado por:

$$e(n) = \frac{1}{2} \sum_{i=0}^{n_c} (S_i(n) - y_i(n))^2 \quad (9)$$

Aunque el aprendizaje debe realizarse para minimizar el error total (ecuación 9), la manera más utilizada es el método del gradiente, el cual es una sucesiva minimización de los errores para cada





patrón $e(n)$, en lugar del error total. Utilizando este método, cada parámetro w se modifica para cada patrón de entrada n como se muestra:

$$w(n) = w(n - 1) - \alpha \frac{\partial e(n)}{\partial w} \quad (10)$$

Donde $e(n)$ es el error para las entradas n y α es una ganancia de aprendizaje, este parámetro influye en la magnitud de desplazamiento en la superficie del error. Se recomienda que α tenga un valor pequeño para mejores resultados, la desventaja de esto, es que el entrenamiento es más lento que si α tuviera un valor grande (Ejemplo: $\alpha = 0.001$ es más lento, pero mejor que $\alpha = 0.1$).

En la figura. 18 se observa un sistema con dos entradas y una red neuronal la cual trata de seguir las salidas del mismo.

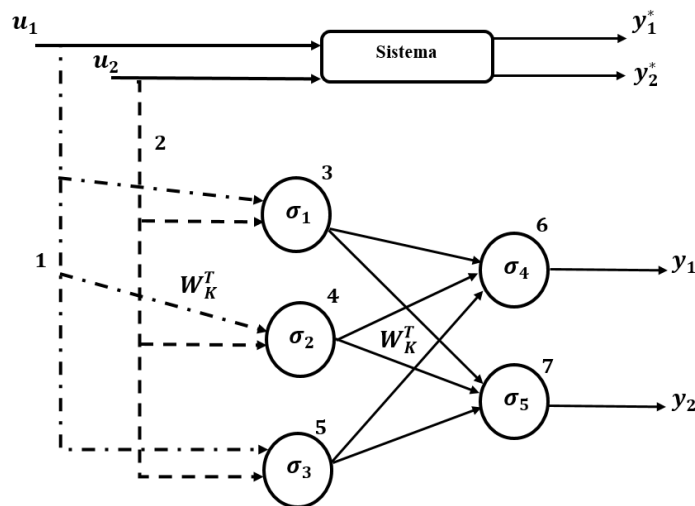


Figura 17. Ejemplo de RN con Backpropagation

Elaboración propia basada en: Presentación en clase de Deep Learning impartida por el Dr. Wen Yui Liu, disponible en <http://www.ctrl.cinvestav.mx/~yuw/teach.htm>





Resolviendo matemáticamente la red neuronal presentada en la figura 17 se obtienen las siguientes salidas en las diferentes etapas:

Feedforward propagation

$$\begin{aligned}O_3 &= \sigma_3(W_{13}u_1 + W_{23}u_2) \\O_4 &= \sigma_4(W_{14}u_1 + W_{24}u_2) \\O_5 &= \sigma_5(W_{15}u_1 + W_{25}u_2) \\y_1 = O_6 &= \sigma_6(W_{36}O_3 + W_{46}O_4 + W_{56}O_5) \\y_2 = O_7 &= \sigma_7(W_{37}O_3 + W_{47}O_4 + W_{57}O_5)\end{aligned}$$

Backpropagation

$$\begin{aligned}e_{01} &= y_1 - y_1^* \\e_{02} &= y_2 - y_2^* \\e_6 &= e_{01}\dot{\sigma}_6 = e_{01} \\e_7 &= e_{02}\dot{\sigma}_7 = e_{02} \\e_3 &= e_6\dot{\sigma}_3W_{36} + e_7\dot{\sigma}_3W_{37} \\e_4 &= e_6\dot{\sigma}_4W_{46} + e_7\dot{\sigma}_4W_{47} \\e_5 &= e_6\dot{\sigma}_5W_{56} + e_7\dot{\sigma}_5W_{57}\end{aligned}$$

Aprendizaje

$$W_{36}(k+1) = W_{36}(k) - \alpha O_3(k)O_6(k) = W_{36}(k) - \alpha O_3(k)e_{01}$$

⋮

$$W_{13}(k+1) = W_{13}(k) - \alpha O_1(k)e_3(k) = W_{13}(k) - \alpha u_1(k)[e_{01}\dot{\sigma}_3W_{36} + e_{02}\dot{\sigma}_3W_{37}]$$





1.5 Estado del arte

¿Qué características debe tener una casa sismo-resistente? [24]

Los terremotos provocan catástrofes que, en gran parte, podrían evitarse utilizando técnicas anti terremotos o sismos resistentes. ¿Cómo debe ser una casa para que soporte terremotos altamente destructivos?

Chile, Japón, California o Nepal son algunas de las zonas activas en cuanto a movimientos de tierra. Sin embargo, no en todos los sitios un terremoto es similar, de igual intensidad y profundidad, o provocan los mismos muertos y heridos. Todo depende en la manera de construir los edificios para que no se derrumben ante posibles sismos. ¿Qué características deben tener los edificios para que sean lo más resistentes posibles? Estas son las más importantes según los especialistas:

- **Altura:** la altura del edificio es uno de los factores más importantes en la resistencia a los terremotos. De hecho, en ciertas ciudades los reglamentos limitaban la altura de los edificios, aunque hoy en día se tiende a valorar su altura en función de la calidad del diseño arquitectónico.
- **Simetría:** un edificio es simétrico respecto a dos ejes en planta si su geometría es idéntica en cualquiera de los lados de los ejes. Cuando un edificio no es simétrico incrementa la posibilidad de que se produzca una torsión en su planta, haciéndolo vulnerable ante un terremoto.
- **Distribución de masas:** los especialistas recomiendan una distribución uniforme de las masas que conforman el edificio, tanto en planta como en altura, cambiando en función de las distintas zonas y alturas en base a la rigidez.
- **Estructuras rígidas en planta:** la mayor cantidad de muros estructurales en la base, mejora la estabilidad y resistencia frente a un movimiento sísmico.
- **Distribución de puertas y ventanas:** la simétrica distribución de los elementos de apertura de las viviendas es importante para aumentar la resistencia del edificio al





colapso, así como un tamaño acorde al resto de la estructura, no debiendo superar más de la mitad del muro.

- **Calidad de los materiales:** otro de los factores esenciales a la hora de medir la resistencia al derrumbe de los edificios es la calidad de los materiales. La buena calidad de la construcción mejora la capacidad de absorción de energía en el movimiento sísmico. Los expertos coinciden en la importancia del hormigón armado y el acero para que el edificio se pueda balancear sin llegar a caerse.
- **Los cimientos:** son clave en la flexibilidad y resistencia de los edificios: cada suelo tiene una cimentación específica tanto en profundidad, forma y tamaño, por lo que es esencial un estudio del terreno previo a la construcción del inmueble.

El trabajo (estrategias para el modelado y análisis sísmico de estructuras históricas) [25] tuvo la finalidad de salvaguardar vidas humanas y también el valor de los edificios históricos y culturales. Al analizar estructuras que fueron construidas con técnicas que actualmente no aplican debido a que los edificios actuales se construyen con materiales y técnicas diferentes, es necesario tener una comprensión total del comportamiento y características de los materiales usados.

Aunque hoy en día se cuentan con teorías y técnicas para el análisis y modelación numérica, que permiten obtener el comportamiento de estructuras complejas con gran precisión. Este tipo de análisis estructural para edificios históricos es insuficiente debido a que la mampostería es un material compuesto que tiene valores de resistencia a compresión y no resiste a tensiones, lo que entorpece proponer modelos que predigan su comportamiento. Se hace la revisión de tres condiciones: las pasadas, actuales y futuras.

- **Análisis de condiciones pasadas:** Este análisis permite conocer la historia de las estructuras a través del tiempo. Identificando valores intrínsecos (culturales, históricos, artísticos etc.) además que ayuda a comprender las condiciones actuales.
- **Análisis de condiciones actuales:** Estas condiciones permiten conocer el grado de daño actual del inmueble y en esta etapa se planea la acción necesaria para mantener la estructura.





- **Análisis de condiciones futuras:** Este análisis es de vital importancia, ya que permite tener una previsión de futuras condiciones.

Para realizar el análisis estructural hay tres métodos y dos tipos de análisis que son comúnmente utilizados:

- **Elementos finitos:** Este método define todo tipo de geometría en dos o tres dimensiones de estructuras continuas además de tomar en cuenta las características de los materiales. Su principal desventaja es el requerimiento de equipos de cómputo de gran poder.
- **Elementos discretos:** Este método es el mejor en caso de estudios discontinuos, ya que el movimiento entre elementos es posible así mismo el cambio de geometría, y los parámetros se actualizan de forma automática. Las estructuras analizadas con este método pueden ser columnas de piedra, esculturas, arcos y templos griegos.
- **Elementos rígidos:** Es un método para el estudio dinámico no lineal, siendo sencillo debido a que no son necesarios muchos elementos, aun para estructuras complejas. Su principal desventaja es que se limita al análisis de dos dimensiones y es poco conocida.
- **Análisis límite:** Este análisis permite conocer el momento de colapso y las cargas máximas, se considera simple y rápido para la etapa de diseño.
- **Análisis elástico lineal:** Al igual que el análisis de límite, el análisis elástico se considere sencillo y rápido, este permite conocer las zonas débiles de la estructura, así como las que tienen algún comportamiento no deseado.

En las figuras 18 y 19 se muestran algunos de los análisis que se realizaron en algunas estructuras históricas de México.

Este trabajo propuso una manera integral de analizar y modelar numéricamente estructuras históricas, la cual se conforma de cinco pasos: Adquisición de datos, selección de la herramienta de análisis, proceso de calibración y vibración, tipo de análisis y el análisis paramétrico. También advierten al ingeniero que en el caso de las estructuras históricas requieren un conocimiento amplio





de la estructura a analizar. De igual manera se enfatiza la importancia que tienen las estructuras “viejas” como patrimonio cultural.




Figura 18. Modelos de elementos finitos de la Catedral y el Sagrario de la ciudad de México
Fuente: [25]




Figura 19. Mecanismo de colapso de la fachada de una iglesia típica den Oaxaca donde
Donde a) es análisis estático no lineal; b) es análisis dinámico no lineal y c) los daños observados después del sismo del 15 de junio de 1999.

Fuente: [25]

En el trabajo (modelación estructural para cargas sísmicas) [26] la modelación física es una herramienta importante en el análisis de estructuras y materiales complejos o con comportamiento desconocido. En este trabajo se presentaron los parámetros más importantes de la modelación física. Teniendo presente que es fundamental la atención en la dificultad que tiene la modelación con cargas dinámicas, en especial las de origen sísmico.





En el trabajo se concluyó que las pruebas sobre modelos a escala son utilizadas mayormente en educación e investigación, también durante el diseño y desarrollo de productos; son considerados una valiosa herramienta para el análisis de estructuras. De igual manera la experimentación con modelos a escala necesita una planeación rigurosa para tener la mayor similitud con la estructura real. La modelación de estructuras permite tener un mayor acercamiento al comportamiento estructural.

En el trabajo (estimación de daño sísmico en edificaciones de mampostería a partir de la aplicación de función de vulnerabilidad simuladas) [27] se aplica un modelo para evaluar el nivel de daño que pueden tener las estructuras de mampostería de un ciudad de Colombia ante un sismo. Dicho modelo esta basado en el uso de funciones de vulnerabilidad o matrices de probabilidad de daño, obtenidas a partir de técnicas de simulación.

Contruyeron funciones para valores de aceleración o movimientos sísmicos de 0.02, 0.05, 0.10, 0.15, 0.20 y 0.25g. En la figura 20 se observa la relación del daño y la aceleración.

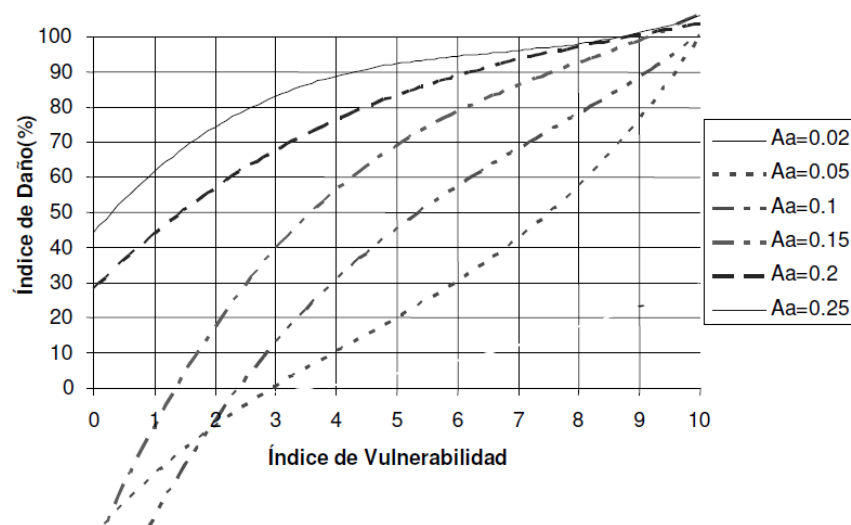


Figura 20. Índice de vulnerabilidad
Fuente: [27]

Para poder estimar el daño en una estructura con el uso de las matrices, se calificaron once parámetros, ver Fig. 21.






Figura 21. Parámetros de vulnerabilidad
Fuente: [27]

Donde:

1. Sistema estructural
2. Calidad del sistema resistente
3. Resistencia estructural
4. Posición de la cimentación
5. Diafragmas horizontales
6. Configuración en la planta
7. Configuración en elevación
8. Distancia máxima entre los muros
9. Tipo de cubierta
10. Estado de conservación





$P(D/V, A = 0.21)$	Rango de daño				
	0~5	6~20	21~45	46~80	81~100
3~5	1.11%	1.89%	5.11%	9.44%	82.44%
4~7	0.94%	0.65%	2.33%	6.69%	89.39%
7~10	1.10%	0.47%	0.39%	1.49%	96.55%

Tabla 8. Matriz de probabilidad de daño para una aceleración de 0.21g
Fuente: [27]

En la figura 22 se observa la representación gráfica de la tabla 8, donde se agrupan los porcentajes de las estructuras con su índice de daño y vulnerabilidad en el caso de un evento sísmico con una aceleración de 0.21g.




Figura 22. Función de vulnerabilidad para una aceleración de 0.21 g
Fuente: [30]

Con el uso aleatorio de parámetros que intervienen en la determinación de la vulnerabilidad sísmica en estructuras de mampostería se evalúa el daño global que podría tener una edificación en caso de un evento sísmico. Es importante mencionar que las funciones no fueron calibradas por falta de datos reales de daño de las estructuras que fueron construidas. Una de las limitantes mencionadas para el desarrollo de este trabajo fue la información disponible, verídica y justificable.

En el trabajo de tesis (Calibración de umbrales de daño sísmico para el análisis de fragilidad sísmica de estructuras de hormigón armado mediante análisis estático no lineal “Push-Over”) [28] para





obtener el grado de maestro en Ingeniería estructural y de la construcción en la Universidad Politécnica de Catalunya en Barcelona en la cual se menciona la importancia del análisis sísmico en una estructura ya que permite garantizar el mejor diseño frente a un sismo, además que brinda el comportamiento estructural con el que se puede caracterizar de manera correcta el nivel de daño que pueda presentar la estructura ante un evento sísmico.

Se definen conceptos de una estructura como por ejemplo la rigidez, resistencia y ductilidad, se tocan los factores que afectan a cada uno de los parámetros mencionados, tanto en nivel de material, sección, elemento y sistema estructural. Se definen los daños locales en rótulas a través de diagramas de momento-curvatura, los niveles de daño manejados son: leve, moderado, severo y completo. Al final, se cuantifican las rótulas y sus niveles de daño local identificadas, con dicho conteo se busca el daño total de los elementos estructurales para tener un daño global.

En (Influencia de la no linealidad de material en las deflexiones inmediatas de vigas de concreto reforzado) [29] Se presentan los resultados analíticos y experimentales de una investigación realizada por el Grupo de Investigación GIES sobre la influencia de la no linealidad de material sobre las deflexiones inmediatas de vigas de concreto reforzado. Bajo condiciones reales y diferentes situaciones de carga fueron ensayados seis vigas de dicho material. El comportamiento teórico de las vigas fue simulado mediante el modelo no lineal de material del programa comercial de elementos finitos ANSYS. La comparación de los resultados del modelo no lineal de ANSYS, las recomendaciones del código de construcción ACI 318, y los ensayos experimentales, mostraron que el comportamiento estructural de una viga simplemente apoyada está fuertemente influenciado por la no linealidad de material.

El concreto se considera un material frágil, presenta una buena resistencia a la compresión, mientras que su resistencia a la tracción es mínima. Normalmente los esfuerzos máximos a tensión que soporta son muy bajos, por lo que para condiciones de diseño se suelen despreciar, y su resistencia a la tracción es suministrada por las barras de acero que sirven como refuerzo. La interacción entre estos dos materiales (concreto y acero) permite tener un material compuesto con el cual se ha construido gran parte de la infraestructura mundial.





En los resultados se observa que para los modelos analizados pero ANSYS presento un comportamiento más rígido que las experimentales, en otras palabras, mostraron menor deformación para el mismo nivel de carga. El error entre los resultados corresponde al 17.5%. El equipo de investigación afirma que teniendo en cuenta las diferentes fuentes de error del proceso experimental con los modelos no lineales de elementos finitos, tiene un grado de exactitud aceptable.

En el trabajo (análisis numérico experimental de un rin de aleación AlSi7Mg) [30] se hicieron investigaciones del comportamiento de un rin de aleación AlSi7Mg, el cual es usado en automóviles compactos de Volkswagen (VW). Para esto, se realizó análisis experimental y numérico. En el primero se utilizó una máquina para prueba de fatiga de momento flexionante, un equipo de medición de láser escáner donde se detectaron las zonas de concentraciones de esfuerzos y la máxima amplitud de desplazamiento en el rin. Mientras que en el segundo se obtuvieron los esfuerzos que ocasionaban la fatiga por el elemento finito, utilizando los paquetes de cómputo ANSYS y Catia. La diferencia de los ciclos de vida de fatiga obtenidos entre ambos análisis fue del 0.6 %. Mientras que el tiempo que se optimizó por el MEF, fue de un 85% menos que el análisis experimental.

Al obtener una estimación de la vida útil del componente, se permite identificar posibles deficiencias geométricas presentes en el diseño, dando mayor flexibilidad al diseñador de realizar los cambios pertinentes. Esto nos lleva a la optimización de tiempos y selección de materiales. En la tabla 9 se muestran las propiedades que se analizan en el rin, de igual manera en la figura 23 se observa el modelo 3D del rin en el software ANSYS.

Propiedad	Ideal	Real	Unidad
Módulo de Young	72.50	71.40	<i>GPa</i>
Relación de Poisson	0.33		
Resistencia de cadencia	90.00	185.95	<i>MPa</i>
Resistencia ultima de tensión	240.00	227.02	<i>MPa</i>
Densidad	2686.00	2614.60	<i>Kg/m³</i>

Tabla 9. Propiedades mecánicas del rin de aleación AlSi7Mg
Fuente: [33]





Figura 23. Modelo 3D de un rin de aleación AlSi7Mg
Fuente: [33]

En la investigación se concluye que el análisis por medio del software indica que el esfuerzo soportado es mayor que al análisis experimental, debido a que ANSYS considera un material ideal, libre de vacío, imperfecciones y discontinuidades en la estructura, lo que es en la realidad esto es poco probable.

En Redes neuronales artificiales para representar la atenuación de la intensidad sísmica [31], el estudio de atenuación de la intensidad sísmica desempeña un papel importante en los análisis de amenaza que incluyan eventos históricos. El mapeo de la atenuación de la intensidad generalmente se realiza por medio de regresiones de la intensidad en función de la distancia. Hoy existen distintas formas para estudiar las características de un evento sísmico por medios instrumentales; sin embargo, los expertos enfrentan el problema del carácter cualitativo de las fuentes de información y el mapeo de la relación entre intensidad, magnitud y distancia para la generación de escenarios de riesgo con base en información histórica.

En los resultados se propone un procedimiento que fue validado para el mapeo de las intensidades de 68 sismos ocurridos en el norte de Suramérica, entre 1766 y 2004. Se encontró que las RNA presentan ventajas respecto a los modelos tradicionales de regresión:

- Preservan de mejor manera el primer momento estadístico.
- Reflejan un error de aproximación menor.



- La varianza explicada por las RNA se comporta mejor que los modelos de regresión estadística.

En la tabla 10, se presentan los tres modelos de las redes donde cada una tiene diferentes entradas y salidas.

Modelos	Variables de entrada		Variables de salida	
1	Magnitud (M)	Intensidad (I)	Distancia (D)	Intensidad epicentral (I_o)
2	Magnitud (M)	Distancia (D)	Intensidad (I)	
3	Magnitud (M)		Intensidad epicentral (I_o)	

Tabla 10. Variables de entrada/salida atenuación sísmica

Fuente: [31]





Capítulo 2 Desarrollo “Simulación y RNAs”

2.1 Metodología aplicada

Se diseñó y construyeron (ver tabla 11) dos modelos 3D de estructuras escolares (U170 y U270), para realizar simulaciones de vibración sobre ellos, simulando las fuerzas de un sismo. Con los resultados se crearon dos bases de datos que sirvieron para el entrenamiento de RNAs que pretenden predecir las fuerzas que generan las vibraciones, alimentadas con las características de los edificios y las de las vibraciones. Al final se propuso el diseño de una interfaz gráfica para un uso simplificado de las redes finales.

2.2 Funcionalidad

El producto final es una interfaz fácil de usar con la cual el usuario puede elegir la red neuronal e ingresar las entradas a la misma. Los resultados que genere la red son mostrados con una gráfica para una mejor interpretación y entendimiento por parte del usuario. Así mismo, se mostrarán las zonas más afectadas de la estructura.

2.3 Modelado 3D y simulación

Con base en los diseños que plantea la SEP, como se muestra en la sección 1.2, se diseñaron los esqueletos que conforman a las estructuras U170 y U270. Inicialmente se debe seleccionar el tipo de perfil que se utilizará como columna y viga, de acuerdo al grosor de las columnas utilizadas en estructuras escolares (0.45 m x 0.5 m) y al catálogo de perfiles estructurales laminados de vigas W [32]. En la figura 24 se muestra el diseño en SolidWorks de los perfiles a utilizar en la construcción de los modelos.





Primer prototipo: Edificio U170 y red neuronal	
Diseño	Modelar un edificio 3D con la estructura de tipo U170 utilizando SolidWorks.
Desarrollo	Realizar simulaciones sobre el modelo diseñado ejerciendo fuerzas similares a las de un sismo y generar una base de datos.
Análisis	Analizar y diseñar la RN, plantear el número de capas y el algoritmo de entrenamiento. Entrenar una red neuronal a partir de la base de datos.
Pruebas	Evaluar el porcentaje de error de la red neuronal usando un conjunto de datos de pruebas.
Segundo prototipo: Edificio U270 y red neuronal	
Diseño	Modelar un edificio con la estructura U270 utilizando SolidWorks.
Desarrollo	Realizar las simulaciones de fuerzas sobre el modelo y generar una segunda base de datos.
Análisis	Diseñar y entrenar una segunda red destinada para el edificio U270
Pruebas	Evaluar la nueva red neuronal con un conjunto de datos de prueba.
Tercer prototipo: Interfaz de usuario	
Análisis	Establecer los requisitos para la interfaz de usuario de acuerdo a la estructura de las redes neuronales.
Diseño	Diseñar bocetos con los elementos necesarios que cumplan los requisitos del análisis.
Desarrollo	Programar la interfaz planteada en los puntos anteriores y se ligan con las redes neuronales.
Pruebas	Probar la interfaz desarrollada se ingresarán entradas las cuales serán procesadas por la red neuronal, si los resultados son los esperados entonces se dirá que la interfaz está trabajando correctamente junto con la red neuronal.

Tabla 11. Metodología utilizada
Elaboración propia.






Figura 24. Perfiles base para columnas y vigas
Elaboración propia basada en [18]

2.3.1 Construcción de los modelos 3D del edificio U170 y U270

Usando los perfiles ya mencionados (fig. 24) y las medidas especificadas en el catálogo de estructuras se construye la estructura U170 (fig. 25) y U270 (fig.26). Para cada diseño se hicieron variaciones como lo es la distancia entre las columnas que fue desde 3.0 m hasta 3.19 m y dos pesos aproximados de los sería su losa, con la finalidad de tener una base de datos más grande y la red neuronal a diseñar tenga más ejemplos para su entrenamiento.




Figura 25. Modelo de la estructura escolar U170
Elaboración propia basada en: [18]



Figura 26. Modelo de la estructura escolar U270
Elaboración propia basada en: [18]

2.3.2 Simulación de fuerzas sobre el modelo de un piso

Para realizar la simulación de fuerzas se utilizará Simulation de SolidWorks, esta herramienta tiene una amplia variedad de áreas de análisis. En este trabajo se usarán dos tipos de estudio, estático y dinámico. Los estudios estáticos proporcionan herramientas para el análisis de tensión lineal de piezas y ensamblajes cargados con cargas estáticas. Con este estudio se puede saber si la pieza se romperá bajo cargas normales, la fatiga y pandeo de diseños delgados. Además, se puede optimizar el diseño. Por otra parte, los estudios dinámicos analizan objetos forzados por cargas que varían en el tiempo. Algunos ejemplos típicos pueden ser cargas de choque de componentes montados en vehículos, turbinas cargadas mediante fuerzas oscilatorias, componentes de aviones cargados aleatoriamente, etc. Se encuentran disponibles tanto linealmente (pequeñas deformaciones estructurales, modelos de material básico) y no linealmente (grandes deformaciones estructurales, cargas importantes y materiales avanzados). Con estos este estudio es posible conocer cuánto se deformará un objeto bajo ciertas circunstancias [33].

2.3.2.1 Configuración utilizada en SolidWorks

El siguiente paso a seguir una vez terminado el modelado de la estructura se realiza la simulación del análisis dinámico de vibración. SolidWorks cuenta con diferentes modalidades para este estudio, y cada uno de ellos brinda diferentes resultados, para este caso utilizamos el estudio de



vibración aleatoria que permite obtener la tensión y desplazamiento en un punto de la estructura según aumenta la frecuencia del movimiento con un desplazamiento que se fija en la configuración. De igual manera se realiza un segundo estudio, pero es un análisis estático, el cual permite conocer el factor de distribución de seguridad de la estructura, el cual se definirá más adelante.

En la figura 27 se muestra la configuración para realizar la simulación del estudio dinámico. Para ejecutar una simulación en SolidWorks es necesario darle cierta información, primero se debe asignar un material al objeto, si el cuerpo está constituido por piezas ensambladas, se pueden configurar diferentes materiales. El segundo paso es indicar las caras del objeto las cuales conforman la base y el tipo de amortiguamiento que en este caso será proporcional conocido como amortiguamiento Rayleigh. Como tercer paso es indicar las cargas externas, que serán dos, la dirección y cantidad del desplazamiento que se ejercerá al objeto y una masa distribuida que representa el peso aproximado de la losa. Por último, se crea la malla, la cual divide en un conjunto finito de elementos más pequeños, si el objeto a analizar tiene una forma irregular o presenta zonas asimétricas (como lo es la estructura escolar) se recomienda seleccionar el enmallado basado en curvatura para evitar generar errores.

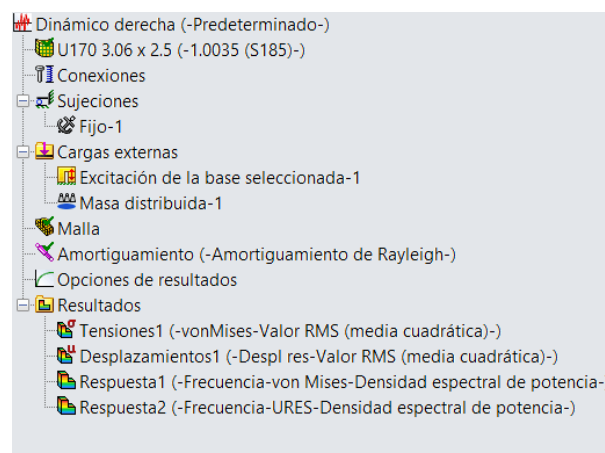


Figura 27. Configuración de estudio dinámico en SolidWorks
Elaboración propia





En la figura 28 se encuentra la configuración para el segundo estudio, el cual es estático y permite conocer el factor de seguridad del objeto. Los parámetros a configurar son los mismos que se explicaron para la figura 27, a diferencia que, en lugar de asignar un desplazamiento en la base, se agrega la fuerza de gravedad. El factor de seguridad identifica las zonas seguras y no seguras de la estructura (más adelante se explica de mejor manera).

Puesto que algunas regiones del modelo experimentan muy poca tensión, el valor máximo del factor de seguridad es muy alto (por encima de 1.800.000). Para que el trazado sea más significativo se recomienda cambiar las escalas de 1 como factor mínimo de seguridad y 100 como máximo factor de seguridad [33].



Figura 28. Configuración de estudio estático en SolidWorks
Elaboración propia

Selección de material

De acuerdo con el tema 1.1.1 Diseño estructural pág. 5 el acero estructural cuenta con sus ventajas y desventajas, pero, aun así, se convierte en un factor importante, ya que define la elasticidad, la resistencia al calor, la resistencia a la tensión y otras fuerzas que sean ejercidas a la estructura. SolidWorks cuenta con una gran cantidad de materiales para aplicarlas al modelo y observar el comportamiento de la estructura de acuerdo al material usado.





En la figura 29 muestra la lista de los diferentes aceros estructurales con los que cuenta SolidWorks (lado izquierdo de la imagen), una vez seleccionado un tipo, en este caso el 1.8901 (S460N), se pueden ver las propiedades de dicho material como lo es el módulo elástico, Coeficiente de Poisson, Módulo cortante, Densidad de masa, Limite de tracción, de compresión entre otros. De igual manera se pueden crear perfiles nuevos configurando las propiedades del material a crear.

The screenshot shows the SolidWorks material selection interface. On the left, a list of materials is displayed, with '1.8901 (S460N)' selected. On the right, the 'Propiedades de material' (Material Properties) dialog box is open, showing the following settings:

- Tipo de modelo: Isotrópico elástico lineal
- Unidades: SI - N/m² (Pa)
- Categoría: DIN Acero (estructural)
- Nombre: 1.8901 (S460N)
- Criterio de fallos predeterminado: Tensión de von Mises máx.
- Descripción: STE 460
- Origen: Límite de tracción y límite elástico para 100<t<=150 mm
- Sostenibilidad: Definido

Propiedad	Valor	Unidades
Módulo elástico	2.100000031e+011	N/m ²
Coeficiente de Poisson	0.28	N/D
Módulo cortante	7.9e+010	N/m ²
Densidad de masa	7800	kg/m ³
Límite de tracción	530000000	N/m ²
Límite de compresión		N/m ²
Límite elástico	380000000	N/m ²
Coeficiente de expansión térmica	1.1e-005	/K
Conductividad térmica	14	W/(m·K)
Calor específico	440	J/(kg·K)
Cociente de amortiguamiento del material		N/D

Figura 29. Selección de materiales en SolidWorks
Elaboración propia

Sujeciones

La configuración de las sujeciones en SolidWorks se observa en la figura 30, donde las pequeñas flechas de color verde indican las caras que se han seleccionado como la base de la estructura.






Figura 30. Selección de sujeciones U170
Elaboración propia

La selección de las caras que forman la base de la estructura es importante, ya que éstas definen la manera en la que el cuerpo se comportará bajo fuerzas externas, la base de la estructura debe ser simétrica para que el peso de la estructura se encuentre equilibrado. Las caras de sujeción del modelo U270 se observa en la figura 31.




Figura 31. Selección de sujeciones U270
Elaboración propia





Cargas externas

Excitación en la base o sujeción seleccionada

En la figura 32 se observa la configuración del movimiento o desplazamiento que se aplicará a la base de la estructura, simulando el movimiento de la tierra cuando se está teniendo un evento sísmico. Se debe elegir uno de los ejes x , y , z e indicar la magnitud de dicho desplazamiento.




Figura 32. Excitación en la base o sujeción seleccionada
Elaboración propia

Masa distribuida (Peso calculado de una losa de concreto)

En la figura 33 se pueden ver las caras de la estructura que fueron elegidas para cargar el peso de la losa de concreto y encargarse de distribuir las fuerzas hacia la base. El peso de la losa se calcula multiplicando el volumen de ésta (la cual varía dependiendo de la separación de las columnas y espesor en cada estructura que se modeló) por la densidad del concreto que es 2400 kg/m^3 .

En el caso del modelo de la estructura U270, se deben aplicar dos masas distribuidas, una corresponde al peso de la losa del entrepiso y otra para la losa superior. En la figura 34 se observa la distribución de los pesos.






Figura 33. Masa distribuida en U170
Elaboración propia




Figura 34. Masa distribuida en U270
Elaboración propia





Creación de malla

Como se mencionó anteriormente, para crear la malla de la estructura modelada, se selecciona el enmallado basado en curvatura, dejando las configuraciones restantes por default. En las figuras 35 y 36 se muestran el enmallado final en la estructura U170 y U270 respectivamente.




Figura 35. Malla en la estructura U170
Elaboración propia

La malla final de cada modelo depende del tamaño y forma del mismo, aunque como ya se mencionó se pueden especificar el número de elementos que conforman a la malla, se decidió dejar por default los valores que utiliza SolidWorks.




Figura 36. Malla en la estructura U270
Elaboración propia



2.4 Creación de la base de datos

Para la creación de la base de datos para el conjunto de entrenamiento que utilizará la red neuronal, se deben elegir las entradas de la misma, dicha selección se realiza identificando los factores que influyen directamente en el comportamiento del sistema a analizar (para este caso, los modelos de las estructuras escolares). Para el estudio de vibración los dos factores son: la frecuencia con la que se realiza el movimiento y la amplitud o desplazamiento que tendrá la base del cuerpo, simulando que es el desplazamiento del suelo que recibe un edificio real durante un sismo. Entre los factores más importantes que definen la resistencia de un edificio en este estudio se seleccionaron la distancia entre las columnas, el material utilizado y el peso aproximado de la losa según su grosor.

En las tablas 12 y 13 se muestran los factores seleccionados como entradas y sus diferentes valores a tomar, mientras que en la tabla 14 se encuentran las salidas. La base de datos se crea simulando el estudio de vibración con todas las posibles combinaciones del valor de las entradas.

Entradas	Valores	Unidades
Frecuencia	0.5, 1, 1.5, 2, 2.5, 3, 3.5, 4, 4.5, 5, 5.5 y 6	<i>Hz</i>
Desplazamiento	2, 4, 8, 16, 24, 36, 48, 60, 76, 90 y 110	<i>mm</i>
Distancia entre columnas	3.0, 3.06, 3.12 y 3.19	<i>m</i>
Grosor de losa	10 y 15	<i>cm</i>
Material	1.0035, 1.0114, 1.0545 y 1.8901	<i>Etiqueta</i>

Tabla 12. Entradas para la red U170
Elaboración propia

Entradas	Valores	Unidades
Frecuencia	0.5, 1, 1.5, 2, 2.5, 3, 3.5, 4, 4.5, 5, 5.5 y 6	<i>Hz</i>
Desplazamiento	2, 4, 8, 16, 32, 48, 64, 90 y 110	<i>mm</i>
Distancia entre columnas	3.0, 3.06, 3.12 y 3.19	<i>m</i>
Grosor de losa	10 y 15	<i>cm</i>
Material	1.0035, 1.0114, 1.0545 y 1.8901	<i>Etiqueta</i>

Tabla 13. Entradas para la red U270
Elaboración propia





Salidas	Valores	Unidades
Tensión 1	0 a 1	N/mm^2
Desplazamiento 1	0 a 1	mm
Tensión 2	0 a 1	N/mm^2
Desplazamiento 2	0 a 1	mm
Distribución del factor de seguridad	0 a 1	Sin unidad

Tabla 14. Salidas para las redes del U170 y U270
Elaboración propia

Como se menciona en el marco teórico las Redes Neuronales han mostrado ser herramientas computacionales muy poderosas, pero tienen ciertas desventajas que se irán mencionando durante el desarrollo. En este punto, la desventaja es la asignación de un valor a un objeto. Por ejemplo, se desea utilizar como entrada al material utilizado en la estructura, se tienen cuatro aceros (tabla 15), que se diferencian en la resistencia que presentan a fuerzas externas. Como entradas para el material se tomará su valor (asignado por SolidWorks). En el caso de que SolidWorks solo presentara el nombre del material se tendría que asignar en valor diferente para cada tipo de material.

Material
Valor/Nombre real
1.0035(S185)
1.0114(S235J0)
1.0545(S355N)
1.8901(S460N)

Tabla 15. Lista de materiales
Elaboración propia

2.4.1 Aumentos entre frecuencias y desplazamientos

En la figura 37 se observan las combinaciones de entrada únicamente para dos de los seis factores. Por ejemplo, para la entrada de frecuencia, cuando el valor sea de 0.5 Hz, se tendrán que realizar simulaciones contra los diferentes desplazamientos (2, 4, 8, 16, 24, 36, 48, 60, 76, 90 y 110 mm); después se cambia el valor de la frecuencia y ésta será simulada contra todos los desplazamientos nuevamente.



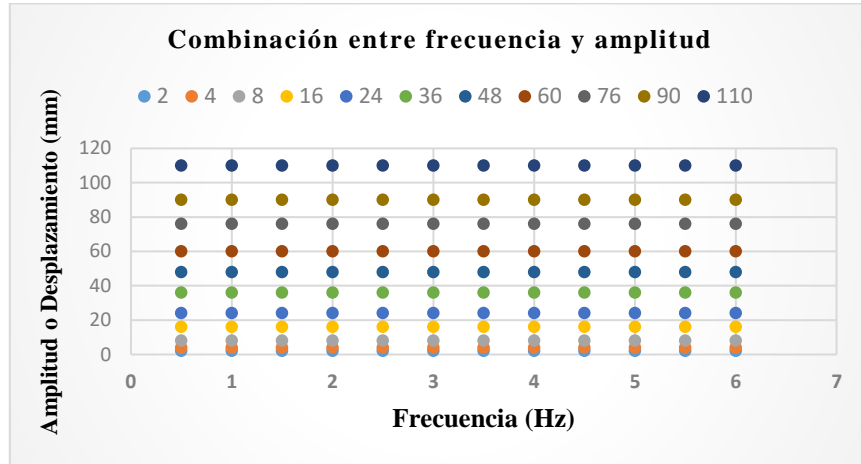


Figura 37. Combinación de frecuencias con desplazamientos
Elaboración propia

2.4.2 Extracción de los datos para la base de datos

Una vez terminada la simulación, SolidWorks permite obtener algo que llama “Gráfica de respuesta” donde se aprecia la tensión o desplazamiento en un nodo. Se debe de recordar que se realiza un enmallado de la estructura, es decir, se divide la estructura completa en un conjunto de elementos finito. Teniendo una gran cantidad de nodos en la estructura (la cantidad de nodos depende del tamaño de la estructura y de la configuración en la creación de la malla). En la figura 38 se muestra el ejemplo del comportamiento de la tensión de acuerdo a la frecuencia en un nodo situado en la conexión de una columna y una viga.




Figura 38. Impresión de pantalla “Gráfica de respuesta”
Elaboración propia





Para crear la base de datos, se seleccionaron 12 puntos, en incrementos de 0.5 Hz. De esta manera se obtienen un total de 24 patrones de salida por simulación. Se obtuvieron 12 resultados de tensión y 12 resultados de desplazamiento con un movimiento horizontal, obteniendo 24 resultados similares, pero con el movimiento vertical, se debe recordar que los movimientos simulan un evento sísmico. En la tabla 16 se tienen los datos que se extrajeron de la gráfica de respuesta proveniente de SolidWorks mientras que en la figura 43 se tiene la nueva grafica con los datos seleccionados.

Frecuencia (Hz)	Tensión (Von Mises)
0.5	1.20E+13
1	3.12E+14
1.5	1.89E+15
2	1.81E+15
2.5	1.19E+15
3	1.00E+15
3.5	1.02E+15
4	1.13E+15
4.5	1.27E+15
5	1.41E+15
5.5	1.56E+15
6	1.73E+15

Tabla 16. Ejemplo de extracción de datos
Elaboración propia




Figura 39. Datos extraídos de la “Gráfica de respuesta”
Elaboración propia





2.5 Creación de las redes neuronales (RNs)

En esta sección se describe la propuesta de la estructura general de la red o redes neuronales que se piensan entrenar, una de las desventajas de las RN es que hasta la fecha no se tiene una fórmula que permita conocer el número de capas y de neuronas óptimo para el entrenamiento, teniendo la necesidad de diseñar más de una red y con el método de prueba y error encontrar la RN que presente el mejor resultado

2.5.1 Diseño de la RN para los modelos U170 y U270

Se tienen cinco entradas, cada una representa un factor importante en la resistencia de la estructura diseñada, así mismo se tienen cinco salidas, dos para tensiones, dos para desplazamiento y un factor de seguridad. Se debe recordar que las tensiones y desplazamientos se diferencian en el tipo de movimiento que se configuró en la simulación (horizontal o vertical). La figura 44 muestra de manera general la estructura de la RN a crear, donde no tiene específicamente el número de capas ocultas y neuronas por capa. Mientras que en la tabla 16 se establecen las variaciones que se tendrán en las RNs, donde se cambia la cantidad de capas ocultas y el número de neuronas, esperando encontrar resultados positivos para alguna configuración.

No. red	No. capas	No. neuronas	Función de activación	Algoritmo de optimización
1	1	11	TANSIG	LM
2	1	22	TANSIG	LM
3	1	44	TANSIG	LM
4	1	11	TANSIG	BR
5	1	22	TANSIG	BR
6	1	44	TANSIG	BR
7	2	11 y 5	TANSIG	LM
8	2	22 y 10	TANSIG	LM
9	2	11 y 5	TANSIG	BR
10	2	22 y 10	TANSIG	BR
11	3	11, 11 y 5	TANSIG	LM
12	3	22, 11 y 5	PURELINE	LM
13	3	22, 11 y 5	PURELINE	BR

Tabla 17. Propuesta de arquitectura de RNs para pruebas
Elaboración propia






Figura 40. Estructura general de la red neuronal
Elaboración propia

2.5.2 Preprocesamiento de los datos

Para tener un mejor aprendizaje de las redes neuronales durante el entrenamiento es necesario someter la base de datos a una normalización y o transformación, de manera que se tengan valores de -1 a 1 o de 0 a 1 . Ya que hay funciones de activación que solo comprenden valores en estos rangos, no podrían regresar una salida con un valor más alto. Por ejemplo, una función sigmoide no podría dar como salida un 10 , para esto se tendría que usar otra función que pueda dar valores más grandes.

2.5.2.1 Variables dummies

Las variables *dummies* son una representación de valores categóricos (Material 1, Material 2, \dots , Material n) en valores binarios ($0 - 1$). En la base de datos se cambiarán las variables de grosor, material, separación entre columnas y la frecuencia. En la tabla 18 se muestra un ejemplo de cada uno de las categorías y su *dummy*. La frecuencia va desde 0.5 e incrementa en razón de 0.5 hasta llegar a 6 , entonces se tienen 12 diferentes variables, en este caso se tienen 12 variables *dummy*, y cada una de ellas toma el valor de 1 cuando se presente alguno de los valores posibles para la frecuencia. Para el caso del desplazamiento, no se tiene una variable *dummy*, éste se normalizó al valor más alto que se tiene para esta entrada (110 mm).

En las salidas se normalizaron los *dummies* a sus valores más altos posibles, de manera se tienen valores de $0 - 1$.





Entradas	Valores	Variables Dummy											
Grosor (cm)	10	0											
Separación (cm)	300	0	0	0	1								
Material (1-4)	100	0	0	0	1								
Desplazamiento (mm)	2	0.0182											
Frecuencia (Hz)	0.5	0	0	0	0	0	0	0	0	0	0	0	1

Tabla 18. Ejemplo de variables Dummies
 Elaboración propia

2.5.3 Redes entrenadas usando Matlab

Matlab tienen integrados diferentes algoritmos de optimización para minimizar el error entre la salida de la red y la deseada, durante los entrenamientos se usaron, Levenberg-Marquardt y Bayesian Regularization. A continuación, se describe cada algoritmo:

Levenberg-Marquardt (Lm): El algoritmo desarrolló a principios de la década de 1960 para resolver problemas de mínimos cuadrados en línea [34]. Es a menudo el algoritmo de propagación hacia atrás más rápido de la caja de herramientas, y es altamente recomendado como un algoritmo supervisado de primera elección, aunque requiere más memoria que otros algoritmos [35].

Bayesian Regularization (Br): Las redes bayesianas regularizadas son más robustas que las redes de backpropagation y pueden reducir o eliminar la necesidad de una validación cruzada prolongada [36]. BR es una función de entrenamiento, que actualiza los valores de peso y sesgo de acuerdo con la optimización de Levenberg-Marquardt minimizando la combinación del error cuadrático y pesos, después establece la combinación correcta para producir una red que pueda generalizar mejor [37]. Este algoritmo es más lento que Lm, pero es eficiente cuando se carece de suficientes datos para el entrenamiento.





2.5.3.1 ToolBox de Matlab

Para el diseño y entrenamiento de las redes neuronales para este proyecto se utiliza el ToolBox propio de Matlab, ya que esta herramienta permite crear las RNs de manera gráfica, sin la necesidad de utilizar código, de manera que se agiliza el proceso y se ahorra tiempo.

Para abrir el ToolBox basta con escribir el comando “nntool” en la consola de Matlab para iniciar la herramienta como se muestra en la figura 45. En esta primera pantalla se pueden importar los datos de entrada y las salidas deseadas para el entrenamiento.

Cuando se hace un clic al botón de Import, se abre una segunda pantalla en la cual se muestran las matrices que se tienen en el momento en el WorkSpace, se debe seleccionar el conjunto de entradas, habilitando el botón de “Input Data” y después dar clic en “Import”, se hace lo mismo para el conjunto de salidas, habilitando el “Target Data”. El procedimiento se muestra en las figuras 41-43.

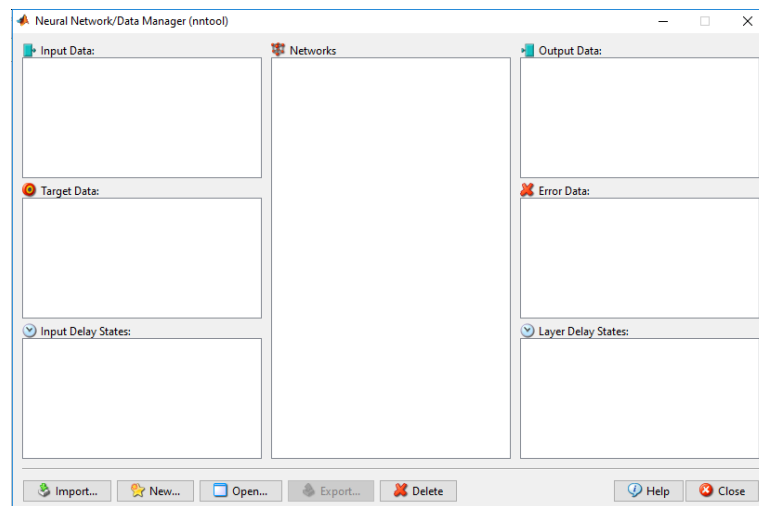


Figura 41. Ventana principal del ToolBox para RNS
Elaboración propia



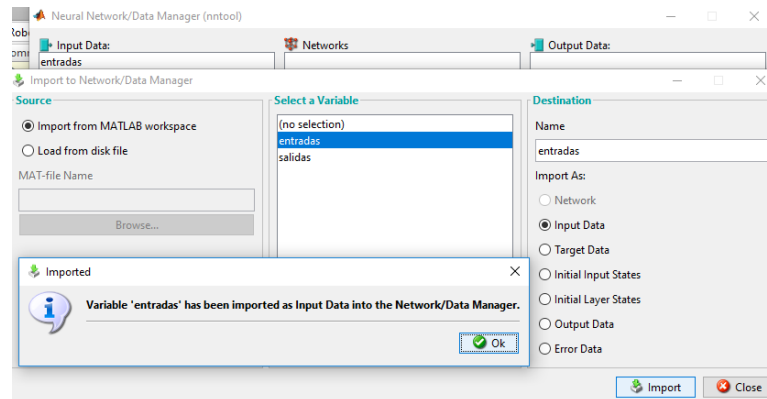


Figura 42. Ventana selección de entradas
Elaboración propia

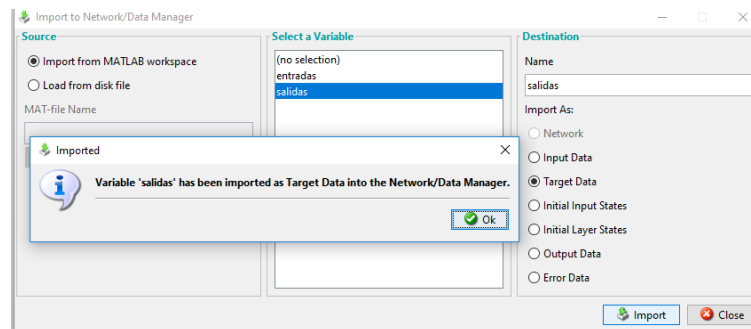


Figura 43. Ventana selección de salidas
Elaboración propia

El paso siguiente es hacer clic en “New”, el cual abre una nueva ventana (fig.44) donde se configuran los diferentes parámetros de la RN deseada, como es la asignación de un nombre, el tipo de red, que en este caso es de Feed-Foward BackPropagation, se seleccionan los datos de entrada y salida que ya han sido importados, se selecciona la función de entrenamiento, la función adaptativa y el número de capas y neuronas en ellas. Una vez asignados los parámetros necesarios, se da un clic en “Create” y se puede ver la estructura final que tiene la RN como se observa en la figura 45.



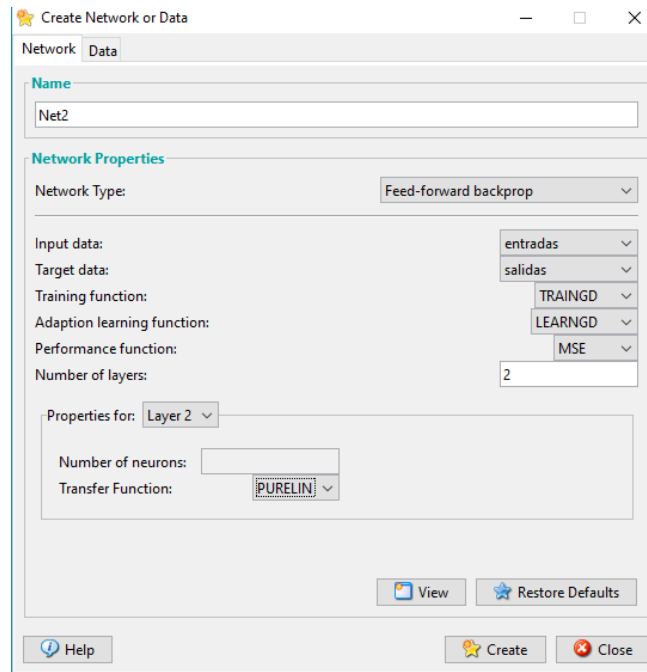


Figura 44. Ventana configuración general de la RN
Elaboración propia

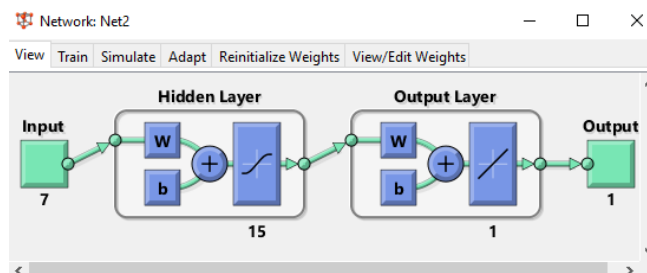


Figura 45. Ventana estructura de la red diseñada
Elaboración propia

El paso siguiente es en la definición de los parámetros para el proceso del entrenamiento de la red, como se observa en la figura 46, en la pestaña “Train/Training Info” se seleccionan una vez más las entradas y salidas (Matlab las llama Inputs y Targets), además que se pueden nombrar las matrices de resultados y errores que genere dicha red. Por otra parte, se deben definir el número de épocas o ciclos en los cuales la red neuronal estará modificando los pesos internos entre las conexiones como se muestra en la figura 47.



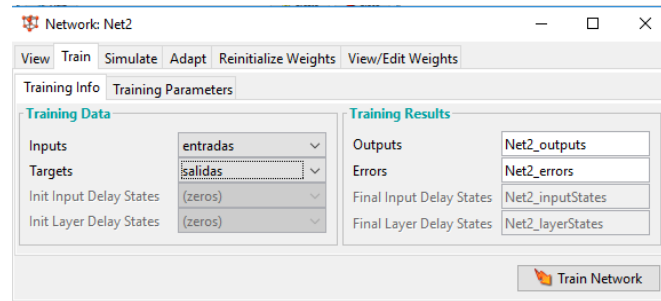


Figura 46. Ventana configuración del conjunto de entrenamiento
Elaboración propia

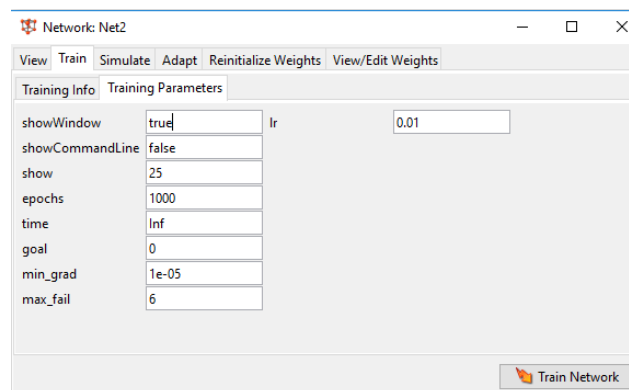


Figura 47. Ventana configuración de parámetros para entrenamiento
Elaboración propia

Luego de hacer clic en “Train Network”, comienza el entrenamiento como se muestra en la figura 47, durante el proceso (el tiempo varía) se puede ver el número de época actual, el tiempo transcurrido, de igual manera se puede observar cómo el gradiente va disminuyendo. Una vez que la red neuronal esta lista, se deben exportar (fig. 49) los resultados, así como la misma red al WorkSpace de Matlab para guardar el proyecto y no perder los datos obtenidos.



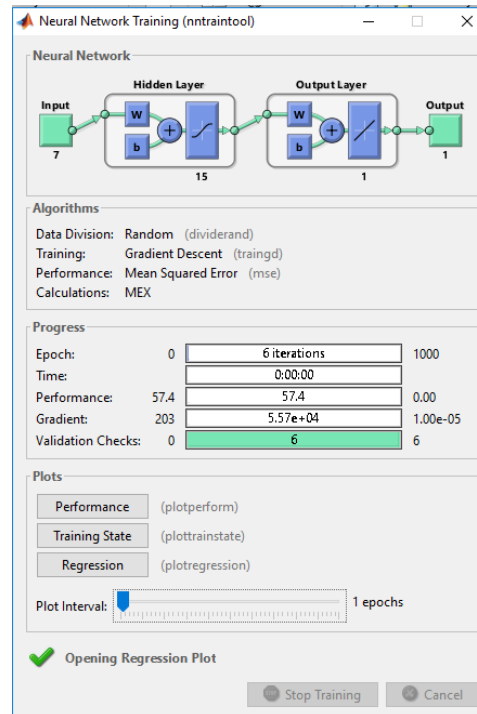


Figura 48. Ventana estado de entrenamiento de la RN
Elaboración propia

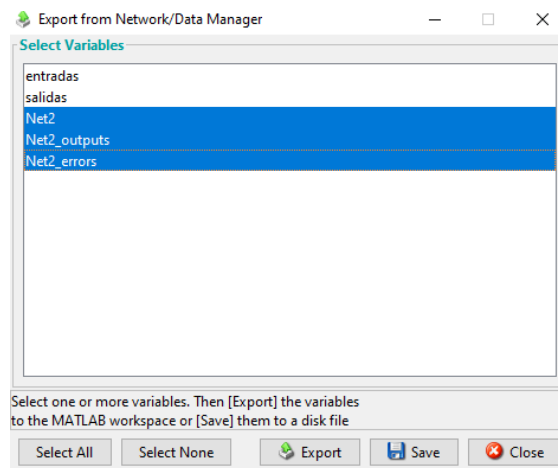


Figura 49. Ventana exportación de los resultados de la RN
Elaboración propia





Capítulo 3 Resultados

3.1 Resultados de la simulación en SolidWorks

En esta sección se muestran los resultados que genera SolidWorks al realizar las simulaciones, con las cuales se pueden identificar las zonas de la estructura que reciben mayor estrés y las zonas más seguras, además de conocer de forma general si es capaz de soportar las vibraciones sin presentar daños que indiquen un riesgo o posibilidad de colapso, y en consecuencia haya pérdidas humanas.

3.1.1 Tensión Von Mises

La tensión de Von Mises está basada en la teoría de Von Mises Hencky, también conocida como teoría de la energía de cortadura o teoría de la energía de distorsión máxima. Dicha teoría dice que un material dúctil comienza a ceder en una ubicación cuando la tensión de Von Mises es igual al límite de tensión. En la mayoría de los casos, el límite elástico es utilizado como el límite de tensión. Es importante tener en cuenta que el límite elástico de un material, es una propiedad que depende de la temperatura del mismo [38].

En términos de las tensiones principales σ_1 , σ_2 y σ_3 la tensión de Von Mises se expresa:

$$\sigma_{vonMises} = \sqrt{\left(\frac{(\sigma_1 - \sigma_2)^2 + (\sigma_2 - \sigma_3)^2 + (\sigma_1 - \sigma_3)^2}{2}\right)} \quad (11)$$

Se presentan los resultados de la Tensión de Von Mises en las dos estructuras (U170 y U270) generados por SolidWorks. En la figura 50 se muestra gráficamente como la tensión en el edificio U170 (fig. 51) va en aumento de acuerdo a la frecuencia, teniendo un crecimiento o pico para las frecuencias de 1.5 a 2.5 Hz; antes de comenzar a disminuir hasta los 3 Hz, donde nuevamente la tensión comienza a aumentar, pero de una manera suave, cuando el desplazamiento definido en la simulación aumentó, se tiene como resultado un aumento en la tensión, sin cambiar el





comportamiento de como la fuerza es ejercida, es decir se tiene un pico entre los rangos de frecuencia mencionados.




Figura 50. Tensión Von Mises en el modelo U170
Elaboración propia

De igual manera, en la figura 51 se observa que no se llega al límite elástico de la estructura, del lado derecho se tiene una pequeña flecha roja, indicando el punto donde el límite se encuentra y la tonalidad que este tiene, el cual es un color azul claro, llegando a ser verde agua, esto significa que la estructura está lejos de la fractura.




Figura 51. Visualización de la tensión en el modelo U170
Elaboración propia





Se tiene el mismo comportamiento de tensión en el edificio U270, los resultados visuales en la estructura y su gráfica están en las figuras 52 y 53.




Figura 52. Tensión Von Mises en el modelo U270
Elaboración propia




Figura 53. Visualización de la tensión en el modelo U270
Elaboración propia





3.1.2 Desplazamiento

Otro de los resultados que brinda SolidWorks es el desplazamiento que presentó la estructura, es decir, cuánto se movió o deformó cada punto del objeto a causa de las fuerzas aplicadas en él. El comportamiento del desplazamiento es similar a la tensión, habiendo un crecimiento cuando la frecuencia está entre 1.5 y 2.5 Hz. La gráfica de los desplazamientos se encuentra en la figura 54 y la visualización del edificio en la 55, en ella se observa que el mayor desplazamiento se encuentra en la parte superior.




Figura 54. Desplazamiento (mm) en el modelo U170
Elaboración propia




Figura 55. Visualización del desplazamiento (mm) en el modelo U170
Elaboración propia





Las figuras 56 y 57 se encuentran los desplazamientos del U270, teniendo el pico entre 1.2 y 2.5 Hz al igual que en el U170, así mismo la parte superior de la estructura es la que presenta el mayor desplazamiento.




Figura 56. Desplazamiento (mm) en el modelo U270
Elaboración propia




Figura 57. Visualización del desplazamiento (mm) en el modelo U270
Elaboración propia





3.1.3 Distribución del factor de seguridad (FDS) [39]

SolidWorks permite evaluar cada nodo del modelo basado en el criterio de error a esto se le conoce como el factor de seguridad. Además, indica la distribución de dicho factor en todo el objeto. De esta manera es posible conocer las áreas del objeto con mayor resistencia, las áreas que reciben una mayor tensión o que simplemente han fallado.

- Un factor de seguridad inferior a 1.0 significa que el material ha fallado.
- Un factor de seguridad de 1.0 significa que el material ha comenzado a fallar.
- Un factor de seguridad superior a 1.0 significa que el material es seguro.

El material que se encuentra en una ubicación empezará a fallar si se aplican nuevas cargas iguales a las actuales multiplicadas por el factor de seguridad resultante, teniendo en cuenta que las tensiones/deformaciones unitarias permanecen en el intervalo lineal. Por ejemplo: un factor de seguridad de 1.0 en una ubicación significa que el material está alcanzando el límite elástico. Por ejemplo, un factor de seguridad de 2.0 significa que el diseño es seguro en esa ubicación y que el material alcanzará el límite elástico si dobla las cargas. Puesto que algunas regiones del modelo experimentan muy poca tensión, el valor máximo del factor de seguridad es muy alto (por encima de 1.800.000). Para que el trazado sea más significativo, cambiando el valor máximo a 100.

El FDS del modelo U170 se presenta en la gráfica de la figura 58, este valor puede cambiar con el material utilizado, en este trabajo se muestra el resultado con cuatro aceros estructurales (tabla 15 y fig. 29), teniendo un FDS desde 3.5 hasta 9.7 aprox. Visualmente se puede decir que en la estructura U170 tiene menor mayor vulnerabilidad en las traveses de 8 m.






Figura 58. Distribución del factor de seguridad en el modelo U170
Elaboración propia




Figura 59. Visualización del factor de seguridad en el modelo U170
Elaboración propia

El FDS del U270 (fig.60 y 61) va desde 3.1 hasta 7.1, en la figura 61 se observa que las columnas y traveses del intermedio y parte superior presentan la mayor variación de factor de seguridad.






Figura 60. Distribución del factor de seguridad en el modelo U270
Elaboración propia




Figura 61. Visualización del factor de seguridad en el modelo U270
Elaboración propia

3.2 Resultados de las redes neuronales desarrolladas

El diseño y entrenamiento de las redes neuronales se hizo utilizando el ToolBox de Matlab, aunque se llevó a cabo un segundo entrenamiento utilizando Python para comparar los resultados.





3.2.1 Redes entrenadas usando MATLAB

3.2.1.1 Redes para el U170

Una vez terminado el entrenamiento se seleccionan las redes con mejor funcionamiento de entre las redes propuestas (tabla 17), esto es, las que tengan un menor error, para ello, se calculó el error cuadrático (MSE) y el coeficiente de correlación (R) entre la salida real y la generada por la red para ambos datos entrenamiento y simulación

El MSE obtiene el promedio de los cuadrados de los errores entre el valor real y el simulado, como en un modelo de regresión. El error cuadrático medio se puede utilizar para evaluar un modelo de regresión, entre más bajo significa, un mejor modelo con un menor error [40]. El r mide la fuerza de una relación lineal entre dos variables. Una correlación de 1 significa que hay una buena correlación y que los resultados simulados son parecidos a los reales mientras que un valor de 0 significa que no existe o es una correlación variada [40][41].

En la tabla 19 se encuentran las redes con menor error cuadrático y mayor coeficiente de correlación, siendo las mejores la Red Br con dos capas ocultas de 22 y 10 neuronas respectivamente, y Br con una sola capa oculta con 22 neuronas.

Como ya se mencionó, la arquitectura de dos capas ocultas con 22 y 10 neuronas, con el algoritmo *Br* presentó el menor MSE y el mejor R , en la figura 66 se tiene el performance del entrenamiento, ésta muestra cómo fue disminuyendo el MSE en cada época con los datos de entrenamiento y pruebas, mientras que en la figura 62, se muestra el ejemplo de la representación de los resultados en las figuras siguientes.





No. red	Red	Error cuadrático medio <i>MSE</i>		Coeficiente de correlación <i>R</i>	
		Entrenamiento	Simulación	Entrenamiento	Simulación
1	Br 22-10	0.00010494	0.00030055	0.9988	0.9961
2	Br 22	0.0001175	0.00030107	0.9987	0.9961
3	Br 11-5	0.00011844	0.0003039	0.9986	0.9961
4	Lm 22-10	0.00012022	0.0003081	0.9986	0.996
5	Lm 44n	0.00012395	0.0003108	0.9986	0.996
6	Lm 11-5n	0.00012648	0.00031441	0.9985	0.996
7	Lm 11-11-5n	0.00012713	0.00031117	0.9985	0.996
8	Br 11n	0.00012802	0.00012802	0.9985	0.9985
9	Lm 22n	0.00012931	0.00030233	0.9985	0.9961
10	Br 44	0.00013014	0.0002987	0.9985	0.9961
11	Lm 11	0.00013209	0.00029202	0.9985	0.9962
12	Lm 22-11-5n PURELINE	0.0017	0.00086998	0.9807	0.9895
13	Br 22-11-5n PURELINE	0.0017	0.00086845	0.9807	0.9897

Tabla 19. Error cuadrático y coeficiente de correlación U170
Elaboración propia




Figura 62. Simbología de los resultados
Elaboración propia

Las x azules representan los resultados que las RNAs generaron, la línea continua es el valor real.





El entrenamiento se realizó con tres conjuntos de datos: de entrenamiento, pruebas y validación, estos conjuntos se seleccionaron de forma aleatoria. El primer conjunto (70% de datos) la red aprende el conocimiento, con los datos de pruebas (15% de datos) y validación (15% de datos) se comprueba qué tan bien aprendió la red, y se configuran los pesos internos para disminuir el error. Cuando ya no es posible disminuir el error configurando los pesos con más épocas el entrenamiento se detiene, sucede igual, si los resultados en la validación en lugar de mejorar empeoran. Una vez que la red ha terminado el entrenamiento se pueden comparar las salidas reales con las que generó la red. En las figuras 63, 64, 65, 66 y 67 se muestra dicha comparación, con la finalidad de que fuera más fácil identificar la salida real con la de la red se tomaron solo 200 datos, las x son las salidas que produjo la red. $T1, D1, T2$ y FDS muestran que la salida de la red sigue el comportamiento de los valores reales, $D2$, tiene variaciones entre los datos 60 a 120.




Figura 63. T1 Br 22-10n U170
Elaboración propia




Figura 64. D1 Br 22-10n U170
Elaboración propia






Figura 65. T2 Br 22-10n U170
Elaboración propia




Figura 66. D2 Br 22-10n U170
Elaboración propia

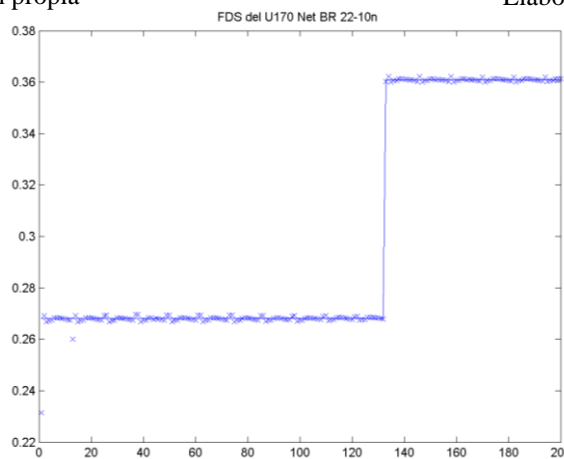


Figura 67. FDS Br 22-10n U170
Elaboración propia

En las figuras 68, 69, 70, 71 y 72 se tiene el porcentaje de error en cada una de las salidas para $T1$, $D1$, $T2$, $D2$ y FDS , en las gráficas se observa que en $T1$, $T2$ y FDS se tiene el menor porcentaje de error, estando en casi 0 para la mayoría de los datos, con la excepción de algunas salidas que se considera ruido en la base de datos, en $D1$ y $D2$ se tienen el mayor porcentaje de error, desde 1000% hasta 6000%.






Figura 68. Porcentaje de error T1
Elaboración propia




Figura 69. Porcentaje de error D1
Elaboración propia




Figura 70. Porcentaje de error T2
Elaboración propia




Figura 71. Porcentaje de error D2
Elaboración propia




Figura 72. Porcentaje de error FDS
Elaboración propia

Terminando el entrenamiento de la red, ésta puede recibir nuevos datos para generar una salida, pueden ser los mismos que se usaron en el entrenamiento si es que no se cuenta con más, aunque lo ideal es tener nuevos para probar el funcionamiento de la red neuronal. Se debe tener en cuenta que estas nuevas entradas deben estar dentro del rango de los valores con los que aprendió la red, de lo contrario los resultados podrían estar lejos del deseado.

Para las redes neuronales, se realizaron simulaciones extra en SolidWorks, con parámetros diferentes a los usados para la base de datos de entrenamiento, por ejemplo, para los datos para entrenar las redes, se tenían valores en desplazamiento de la base de 2, 4, 8, 16, 24, 36, 48, 60, 76, 90 y 110, y





generar datos para simular la red, se usaron valores como 20, 55 y 70, de esta forma los valores no salen del rango de conocimiento de la red.

En las figuras 73, 74, 75, 76 y 77 se muestran los resultados de la simulación de la red, para ello se usaron 144 datos. Las x son las salidas que generó la red, se puede observar que estos datos siguen el comportamiento de las salidas deseadas, teniendo la mayor exactitud en $D1$, $T2$ y FDS .




Figura 73. Simulación de T1
Elaboración propia




Figura 74. Simulación de D1
Elaboración propia




Figura 75. Simulación de T2
Elaboración propia




Figura 76. Simulación de D2
Elaboración propia






Figura 77. Simulación de FDS
Elaboración propia

Los resultados que generaron las diferentes redes neuronales pertenecientes a los datos del edificio U170, se presentan las mismas salidas $T1$, $D1$, $T2$, $D2$ y FDS , para todas ellas, es la misma interpretación. La posición de las salidas en las figuras se representa en la siguiente imagen (fig. 78). Dicha posición será la misma para los resultados de las redes entrenadas para la estructura U270.

T1	D1
T2	D2
FDS	

Figura 78. Posicionamiento de salidas en figuras
Elaboracion propia



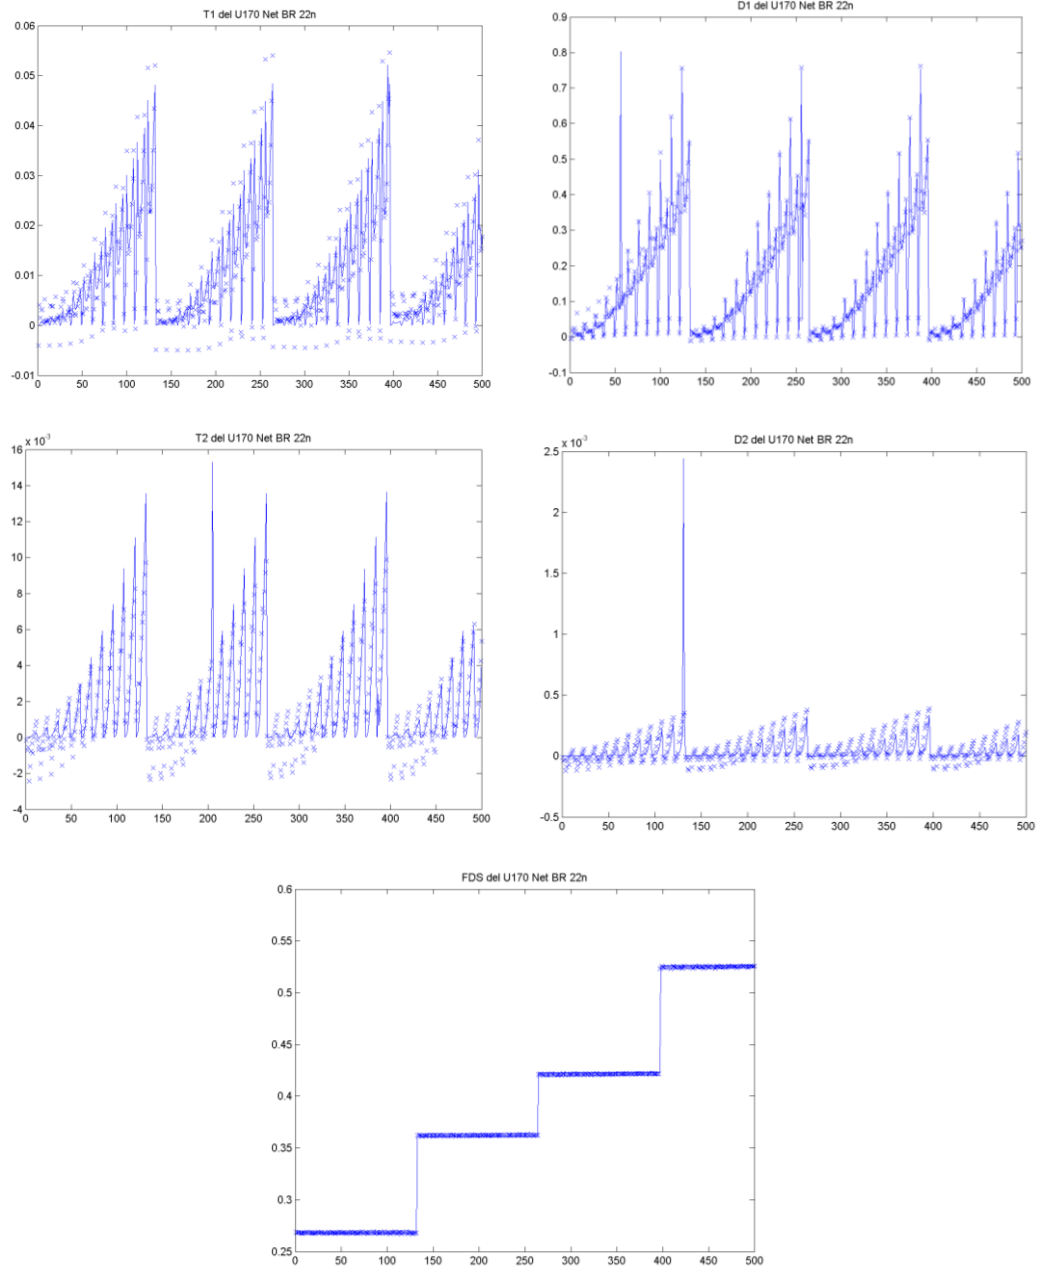


Figura 79. Resultados Net BR 22n U170

Resultados de la red neuronal del modelo U170, con arquitectura de una capa oculta con 22 neuronas y con un algoritmo de Regularización Bayesiana.
Elaboración propia



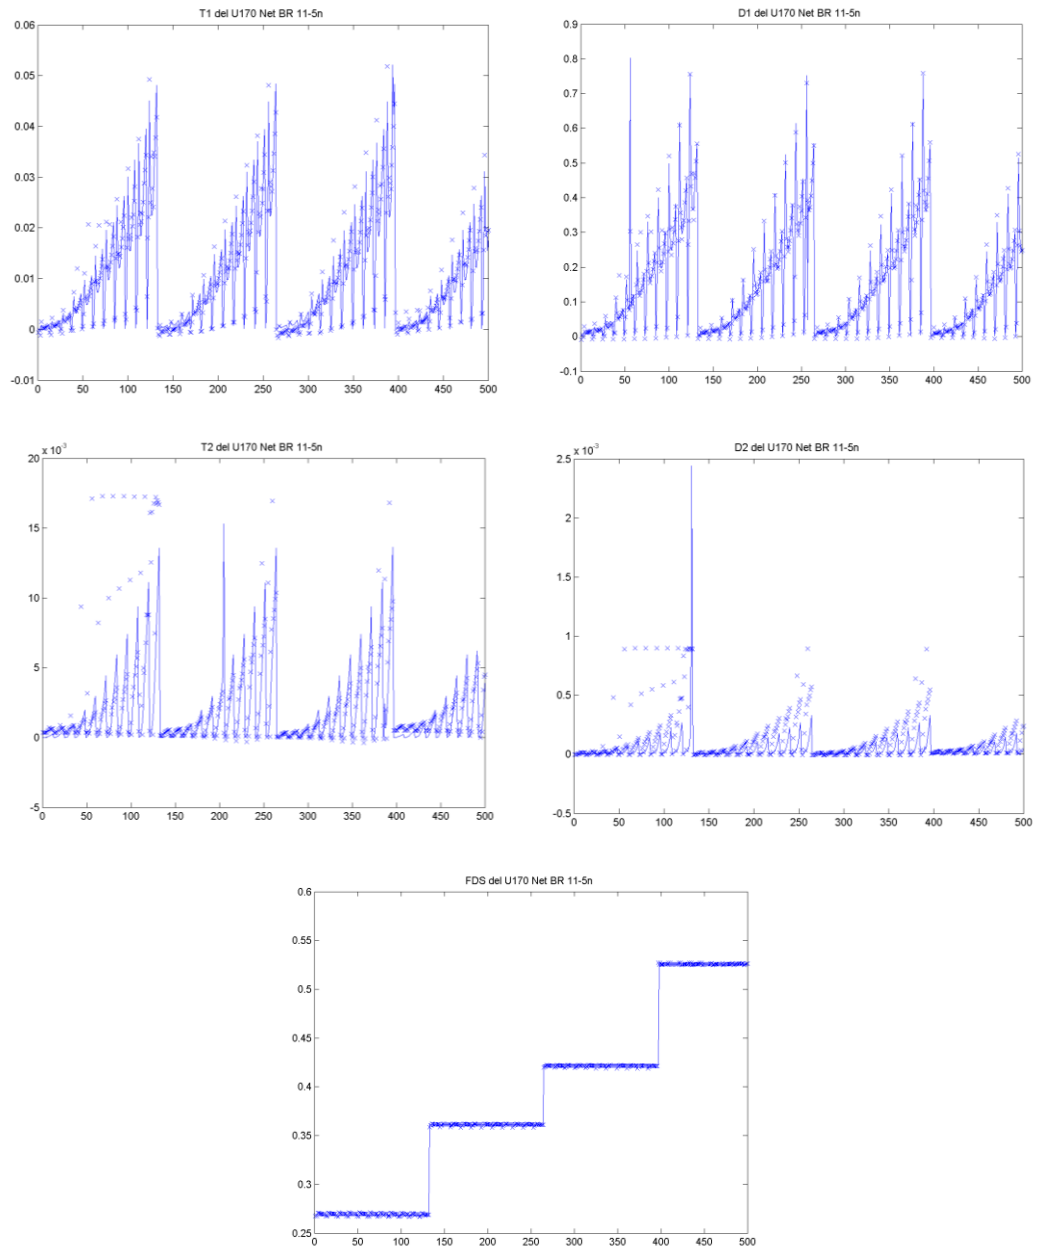


Figura 80. Resultados Net BR 11-5n U170

Resultados de la red neuronal del modelo U170, con arquitectura de dos capas ocultas con 11 y 5 neuronas en cada una y con un algoritmo de Regularización Bayesiana.
Elaboración propia.



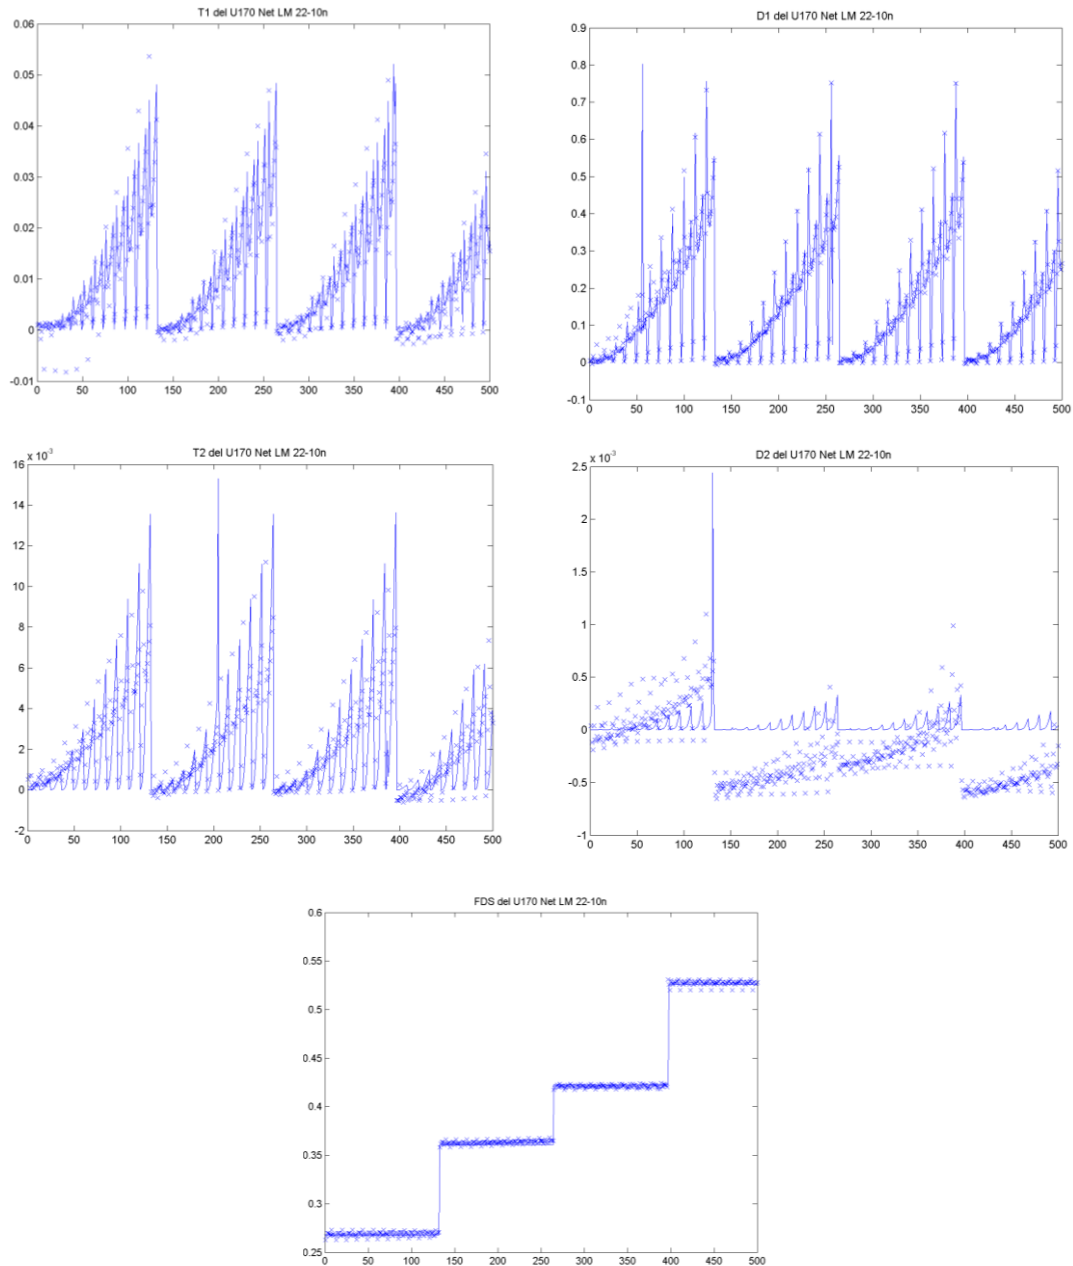


Figura 81. Resultados Net LM 22-10n U170

Resultados de la red neuronal del modelo U170, con arquitectura de dos capas ocultas con 22 y 10 neuronas en cada una y con un algoritmo de Levenberg-Marquardt.
Elaboración propia



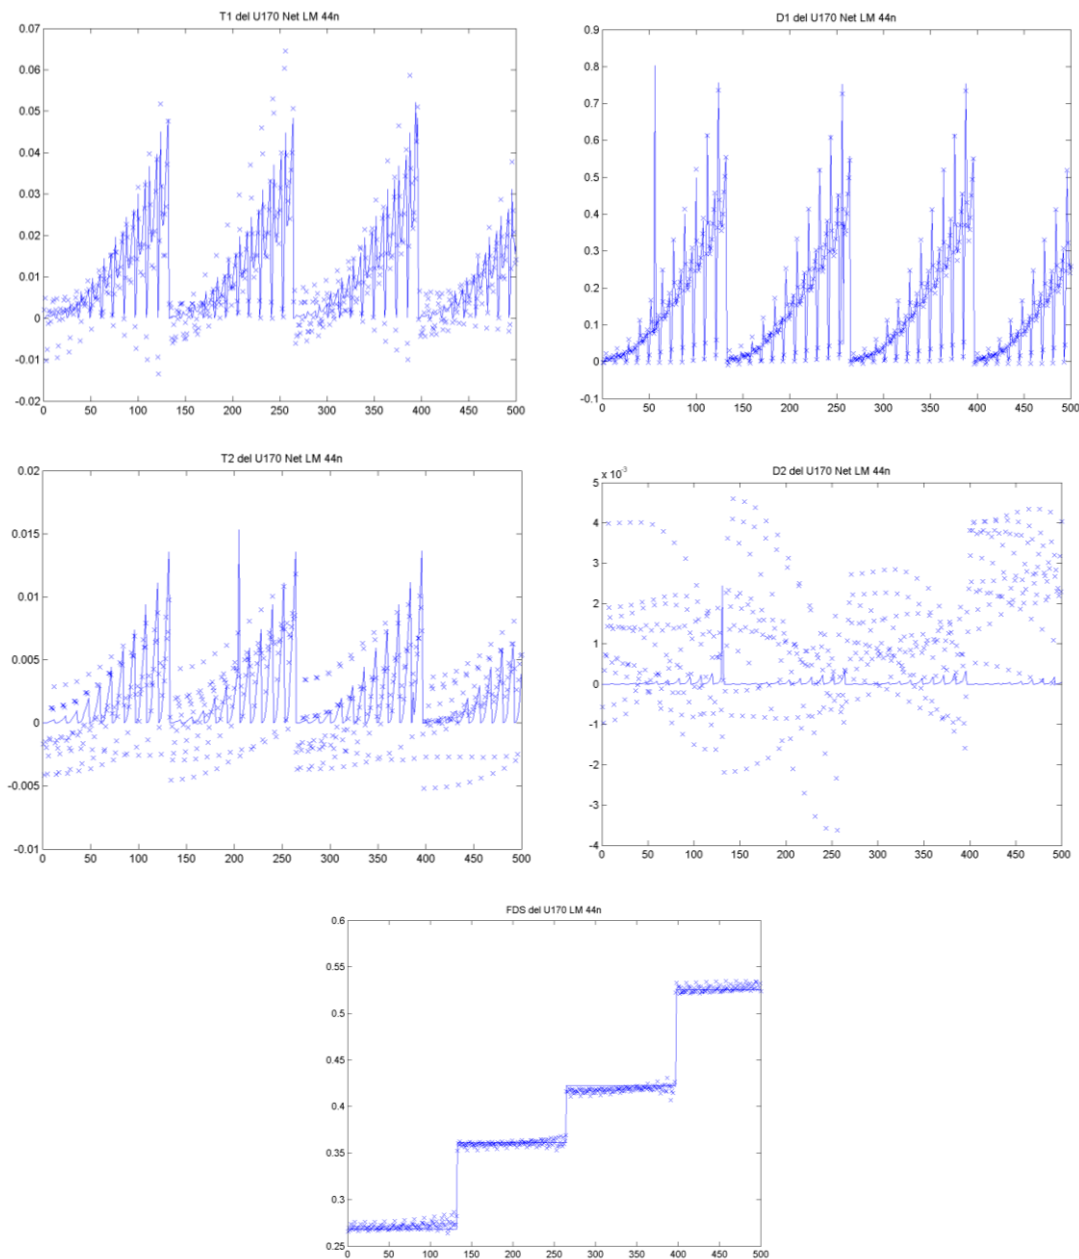


Figura 82. Resultados Net LM 44n U170

Resultados de la red neuronal del modelo U170, con arquitectura de una capa oculta con 44 neuronas y con un algoritmo de Levenberg-Marquardt.

Elaboración propia



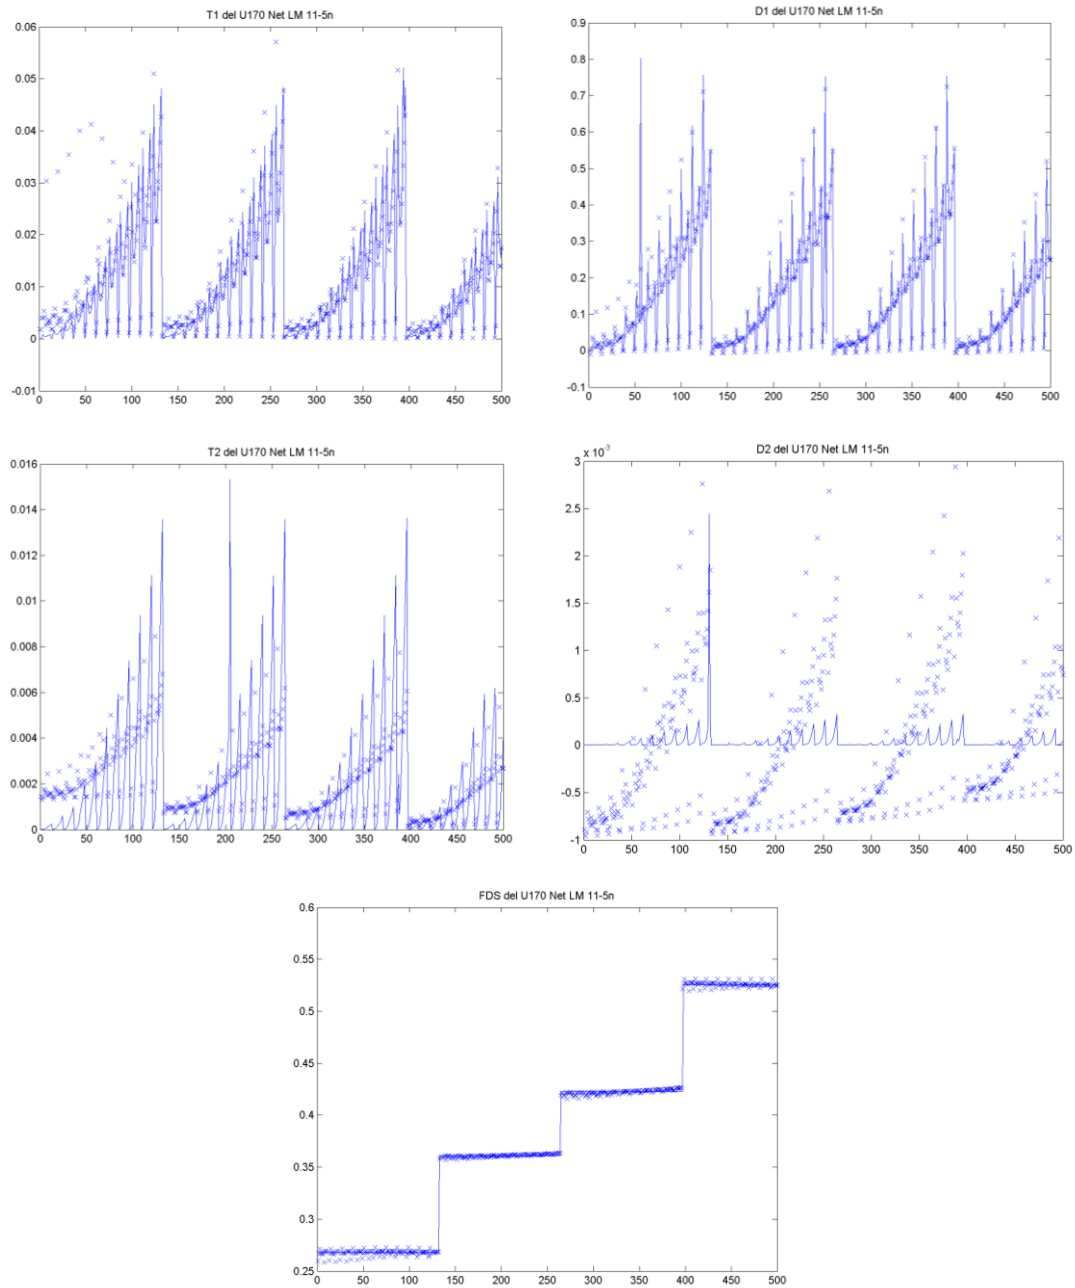


Figura 83. Resultados Net LM 11-5n U170

Resultados de la red neuronal del modelo U170, con arquitectura de dos capas ocultas con 11 y 5 neuronas en cada una y con un algoritmo de Levenberg-Marquardt.

Elaboración propia



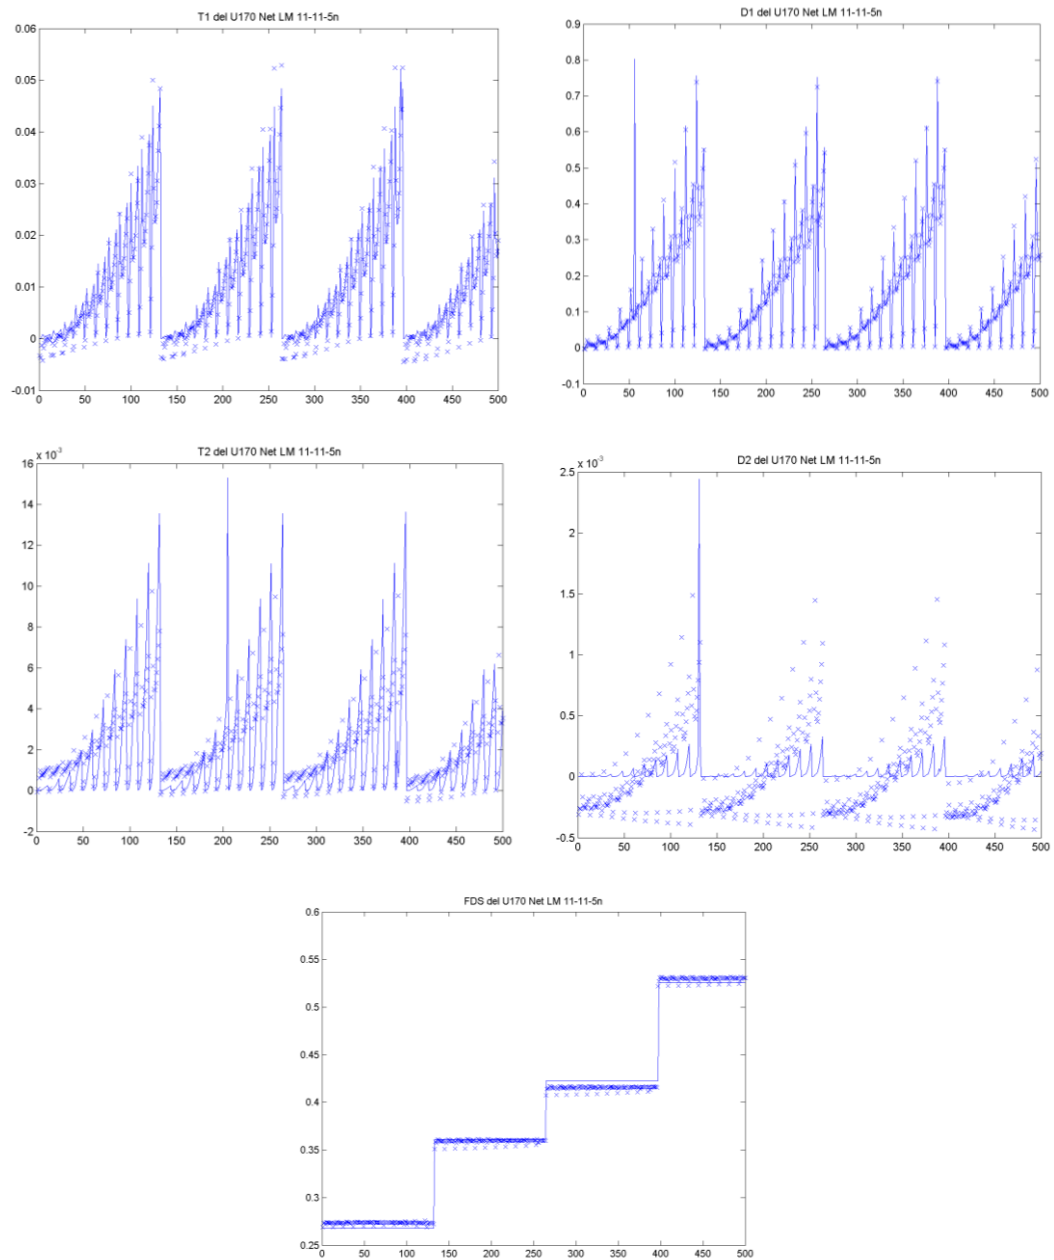


Figura 84. Resultados Net LM 11-11-5n U170

Resultados de la red neuronal del modelo U170, con arquitectura de tres capas ocultas con 11, 11 y 5 neuronas en cada una y con un algoritmo de Levenberg-Marquardt.
Elaboración propia



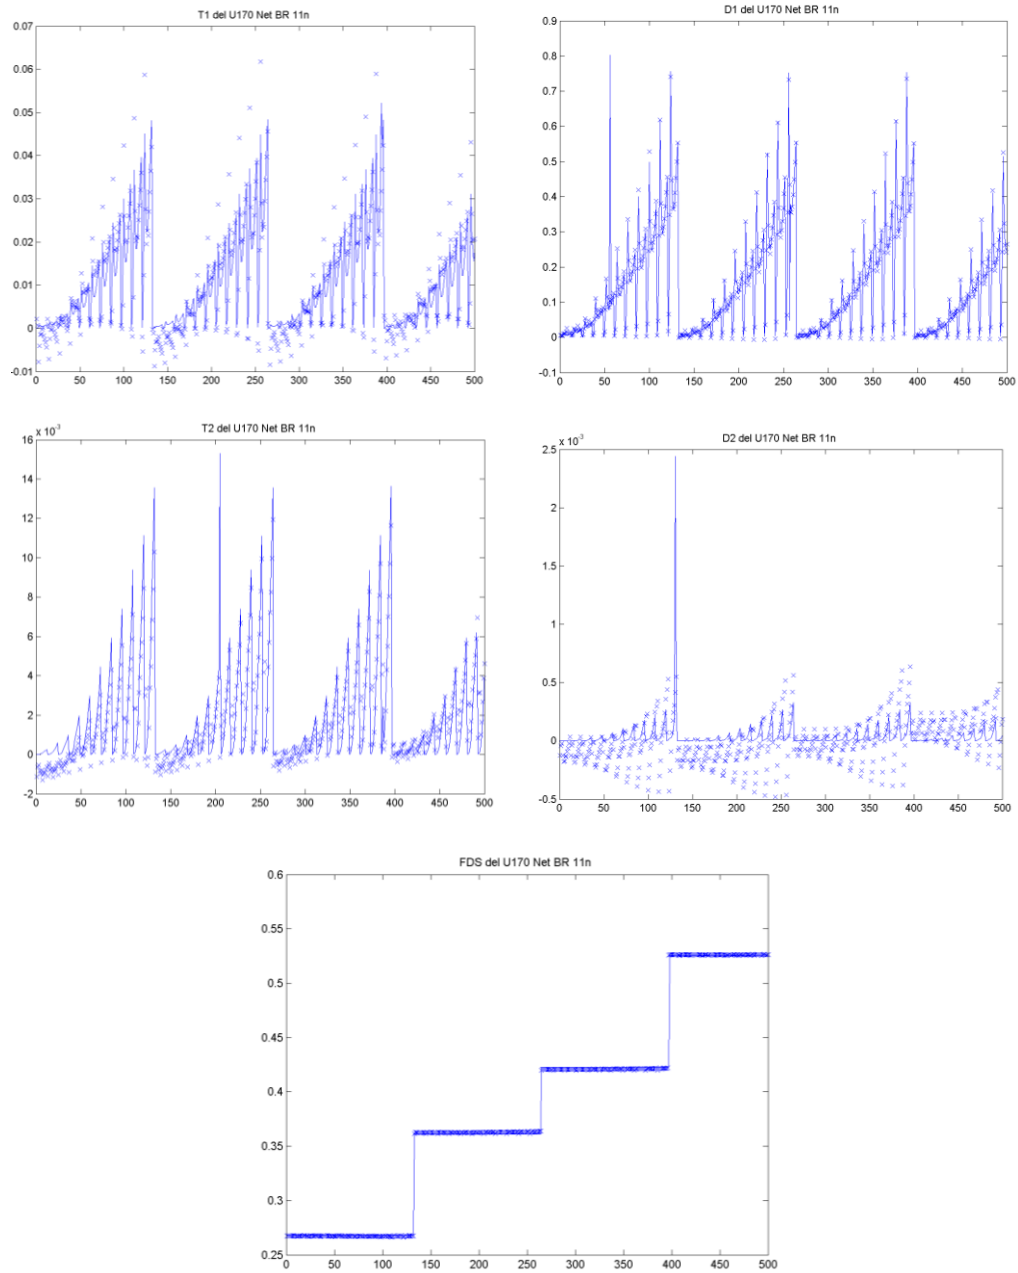


Figura 85. Resultados Net BR 11n U170

Resultados de la red neuronal del modelo U170, con arquitectura de una capa oculta con 11 neuronas y con un algoritmo de Regularización Bayesiana.
Elaboración propia



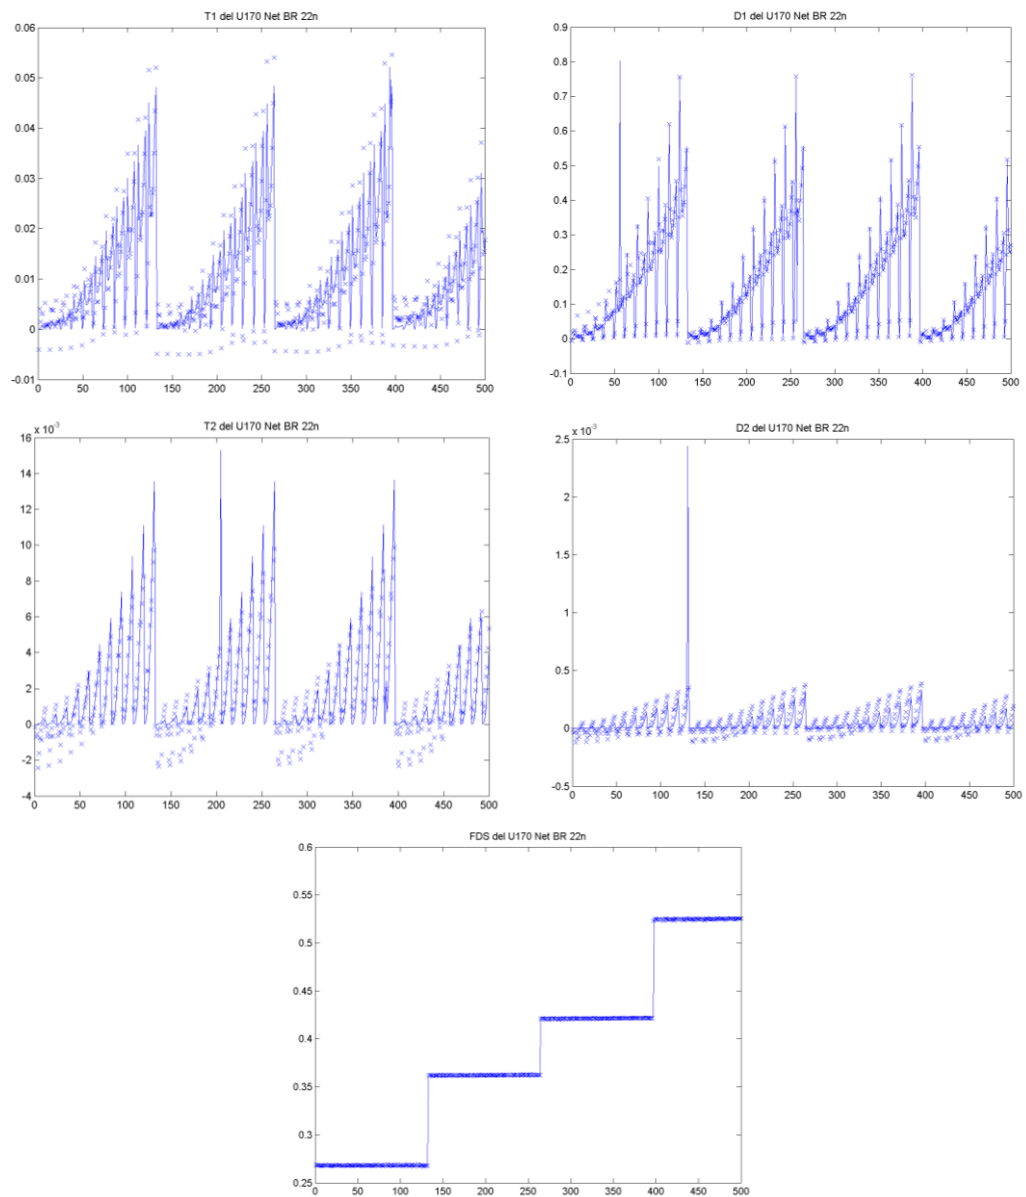


Figura 86. Resultados Net LM 22n U170

Resultados de la red neuronal del modelo U170, con arquitectura de una capa oculta con 22 neuronas y con un algoritmo de Levenberg-Marquardt.

Elaboración propia



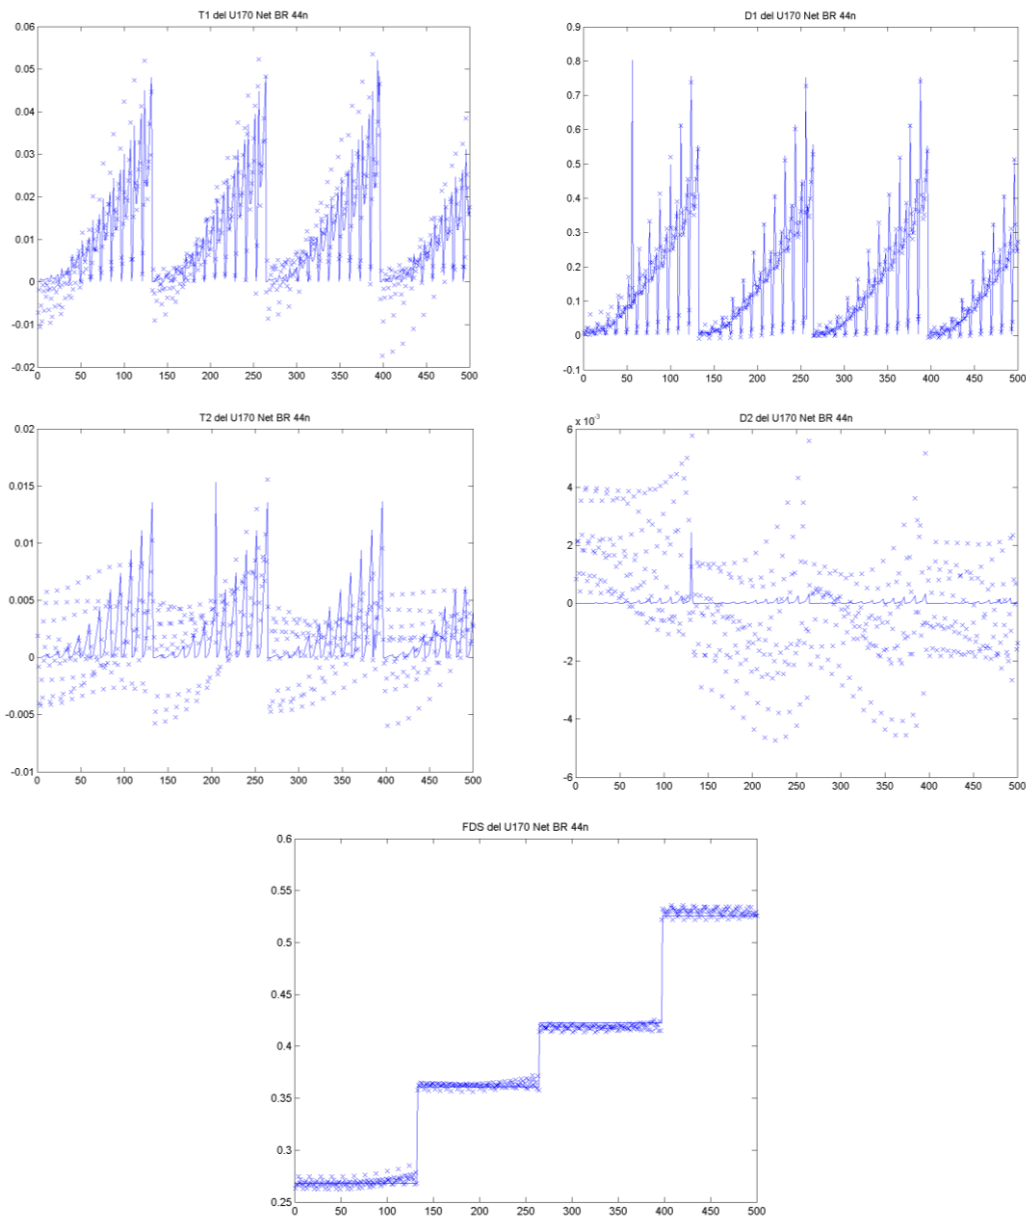


Figura 87. Resultados Net BR 44n U170

Resultados de la red neuronal del modelo U170, con arquitectura de una capa oculta con 44 neuronas y con un algoritmo de Regularización Bayesiana.

Elaboración propia



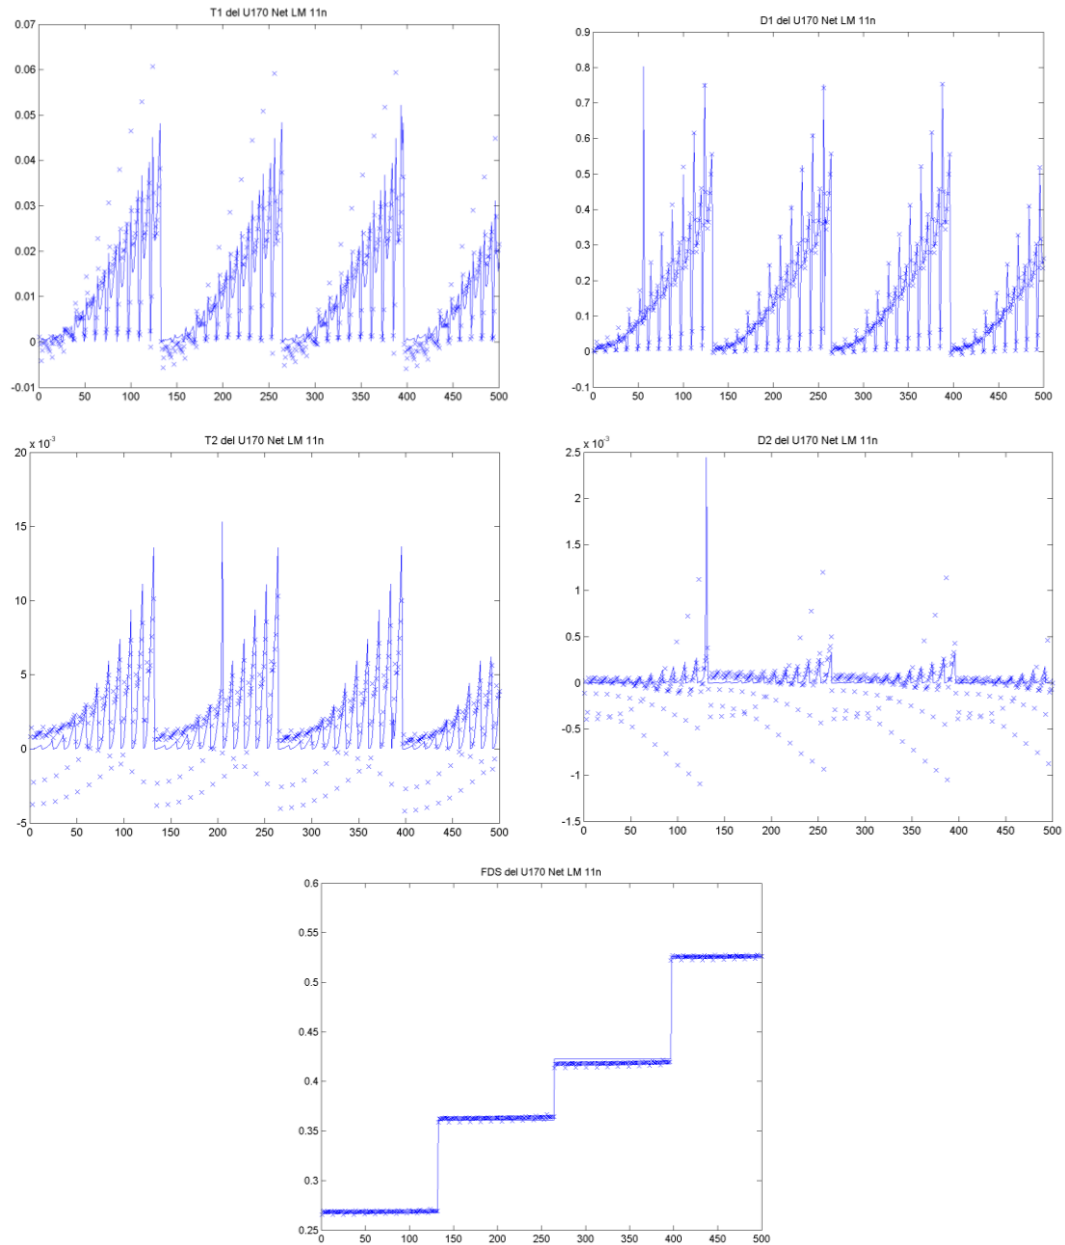


Figura 88. Resultados Net LM 11n U170

Resultados de la red neuronal del modelo U170, con arquitectura de una capa oculta con 22 neuronas y con un algoritmo de Levenberg-Marquardt.
Elaboración propia



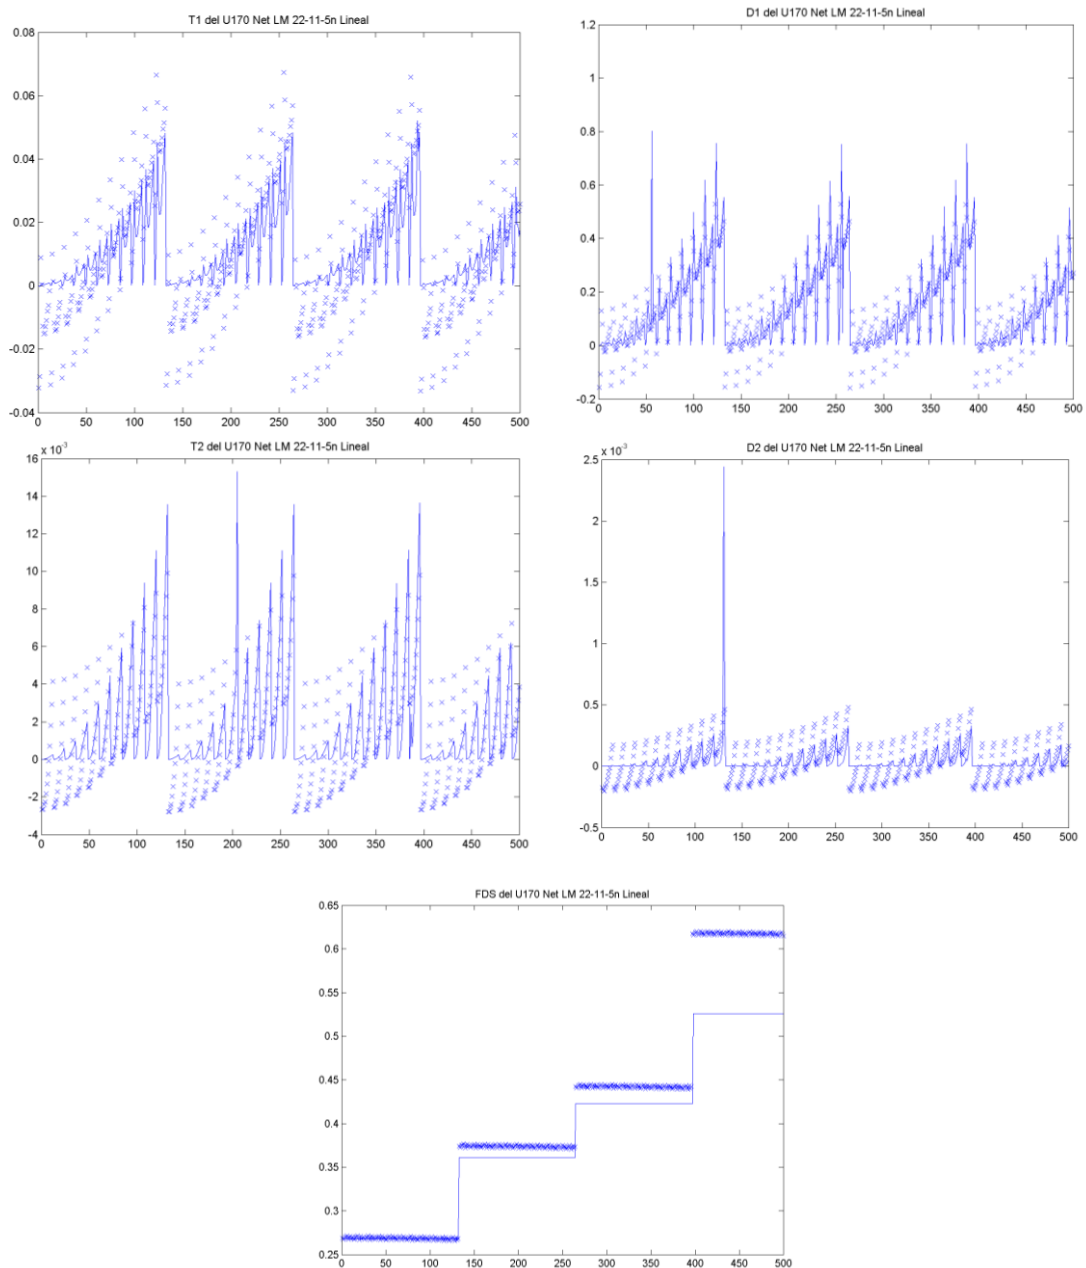


Figura 89. Resultados Net LM 22-11-5n Pureline U170

Resultados de la red neuronal del modelo U170, con arquitectura de tres capas ocultas con 22, 11 y 5 neuronas en cada una y función de activación PURELINE y con un algoritmo de Levenberg-Marquardt.

Elaboración propia



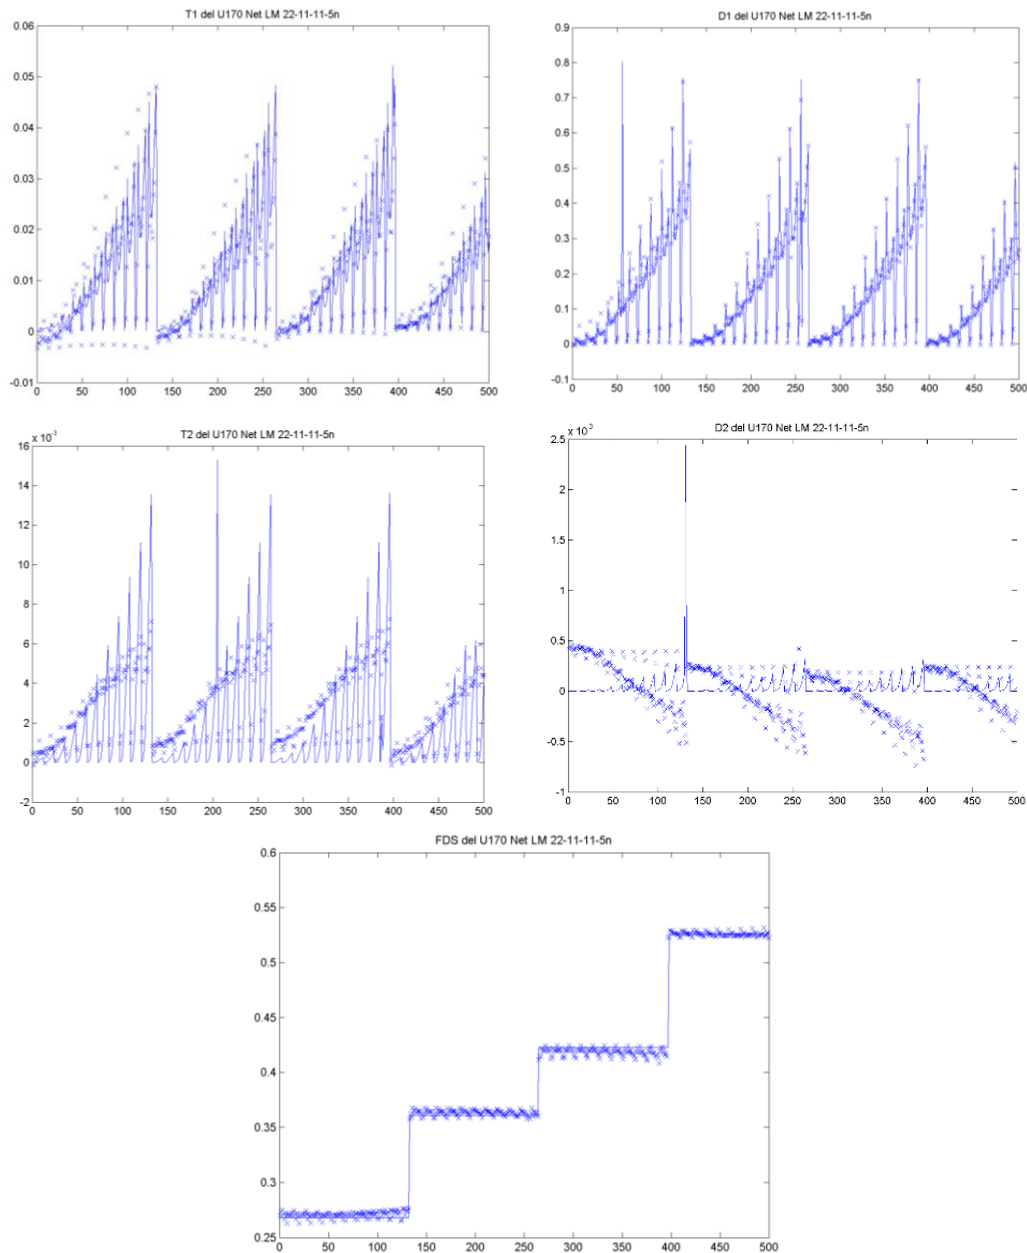


Figura 90. Resultados Net BR 22-11-5n Pureline U170

Resultados de la red neuronal del modelo U170, con arquitectura de tres capas ocultas con 22, 11 y 5 neuronas en cada una y función de activación PURELINE y con un algoritmo de Regularización Bayesiana.

Elaboración propia





En las figuras hubo variaciones en cada una de las salidas para las diferentes redes entrenadas, se encontró que en la salida 3 y 4 (*T2* y *D2*) hay mucho mayor error, debido a esto se realizó un entrenamiento extra, separando las salidas 1 y 2 de las salidas 3, 4 y 5, en dos redes diferentes para probar si de esta manera el resultado de dichas salidas podía mejorar. En la tabla 20 se tiene el *MSE* y *R*, mientras que en la figura 91 se observan las salidas.

		Error cuadrático medio	Coefficiente de correlación	Error cuadrático medio	Coefficiente de correlación
No. Red	Red	T1 y D1		T2, D2 y FDS	
1	BR 22	1.08E-04	0.9972	7.82E-07	1

Tabla 20. MSE y Coeficiente de correlación Net BR 22n Salidas separadas U170
Elaboración propia

En el experimento de entrenar las salidas *T2*, *D2* y *FDS*, se puede apreciar a simple vista que los resultados de estas salidas mejoraron ya que sigue el comportamiento original, en comparación con las redes anteriores. El coeficiente de correlación de esta última fue de 1, el mientras que para la red con mejor comportamiento que fue la de red Br 22-10n tuvo un coeficiente de 0.9988 además de tener un menor error cuadrático de $7.82E - 07$ contra $1.05E - 04$. Sin embargo, la red entrenada con solo *T1* y *D1* no superó los resultados de la Br 22-10n ya que el MSE fue 1.08E-04 y con coeficiente de correlación de 0.9972. Las comparaciones anteriores se pueden observar en la tabla 21, y en las figuras 83 y 84 se presentan graficados el *MSE* y el *R*.

No. Red	Red	Error cuadrático medio	Coefficiente de correlación
1	BR 22 <i>T1</i> y <i>D1</i>	1.08E-04	0.9972
2	BR 22 <i>T2</i> , <i>D2</i> y <i>FDS</i>	7.82E-07	1
3	BR 22-10 (Todas las salidas)	1.05E-04	0.9988

Tabla 21. Comparación de MSE y Coeficiente de Correlación U170
Elaboración propia



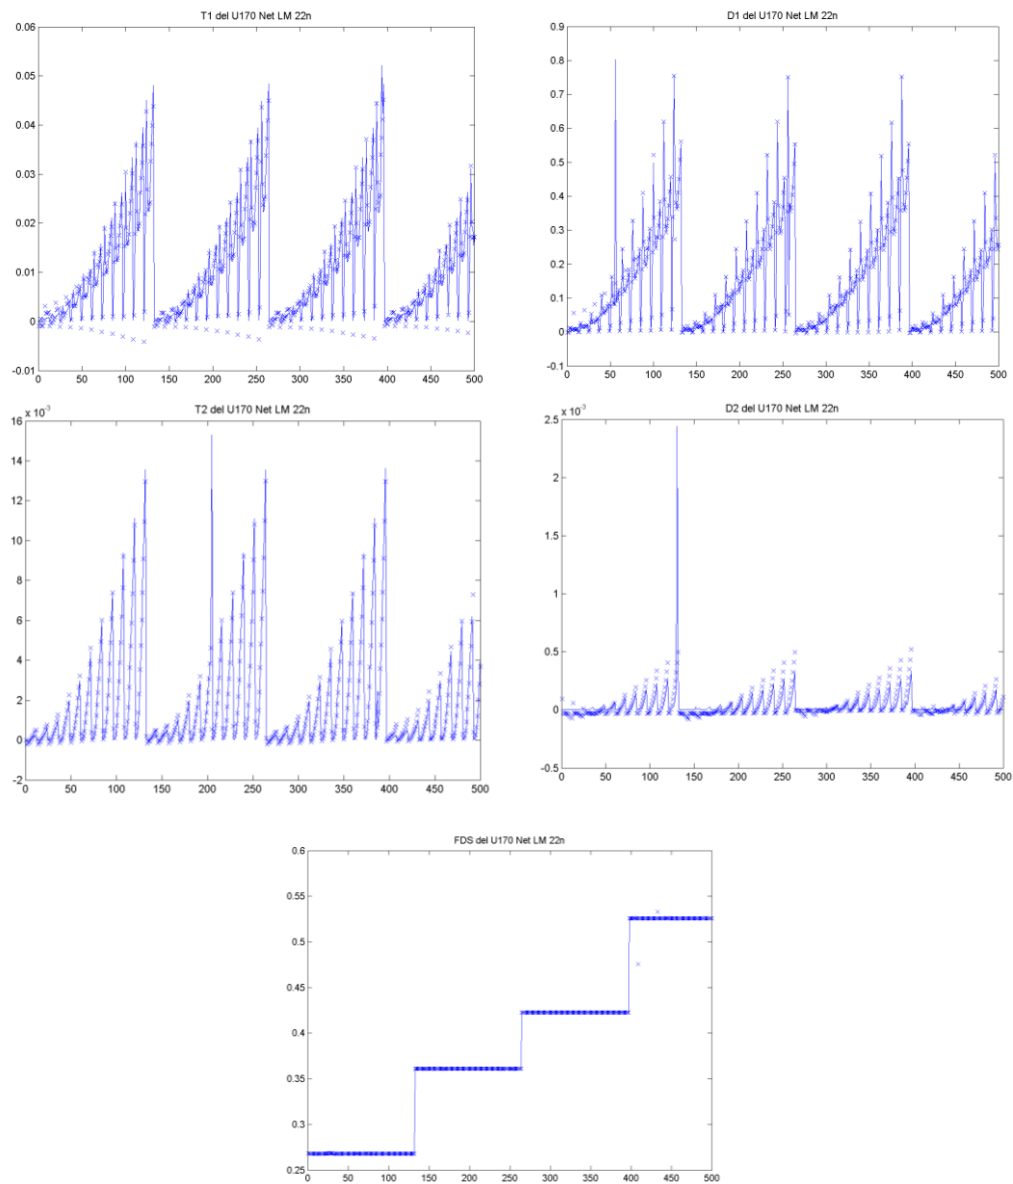


Figura 91. Resultados Net BR 22n Salidas separadas U170

Resultados de dos redes neuronales del modelo U170, con arquitectura de una capa oculta con 22 neuronas función de activación y con un algoritmo de Regularización Bayesiana.

Elaboración propia





Comparación de MSE de las mejores redes




Figura 92. Comparación de MSE de las mejores redes U170
Elaboración propia

Comparación de R de las mejores redes




Figura 93. Comparación de R de las mejores redes U170
Elaboración propia

3.2.1.2 Redes para el U270

En esta sección están enlistadas las diferentes RNs entrenadas para la estructura U270 siendo la número 1 la que presenta un menor error, las salidas son las mismas ($T1, D1, T2, D2$ y FDS) y siguiendo posicionamiento de las figuras anteriores (fig. 78).

Para el modelo U270 la red que dio mejores resultados (tabla 22) consta de una sola capa oculta con 44 neuronas en ella y con un algoritmo de Regresión Bayesiana, para el U170 la mejor fue la Br de dos capas con 22 y 10 neuronas.





No. Red	Red	Error cuadrático medio MSE		Coeficiente de correlación R	
		Entrenamiento	Simulación	Entrenamiento	Simulación
1	Br 44	5.86E-05	0.0011	0.9995	0.9918
2	Lm 22-10	6.96E-05	0.0074	0.9994	0.9439
3	Br 11-5n	8.50E-05	7.15E-04	0.9993	0.9946
4	Br 22n	8.90E-05	7.49E-04	0.9993	0.9943
5	Lm 44n	9.97E-05	0.0267	0.9992	0.8371
6	Lm 11-5n	1.02E-04	0.0956	0.9992	0.6818
7	Lm 11-11-5n	1.04E-04	0.1768	0.9992	0.4994
8	Lm 22n	1.31E-04	0.0172	0.9989	0.8864
9	Br 22-10	1.60E-04	0.0011	0.9987	0.9915
10	BR 11n	1.98E-04	6.53E-04	0.9984	0.9949
11	Lm 11n	2.33E-04	2.33E-04	0.9981	0.9981
12	Lm 22-11-5n PURELINE	0.0031	0.0027	0.9748	0.979
13	Br 22-11-5n PURELINE	0.0031	0.0013	0.9748	0.9915

Tabla 22 MSE y Coeficientes de correlación de las redes del U270

Elaboración propia

En las figuras 94 y 95 se presenta el performance o disminución del MSE de la red Br 44n y la regresión lineal con todos los datos durante el entrenamiento.

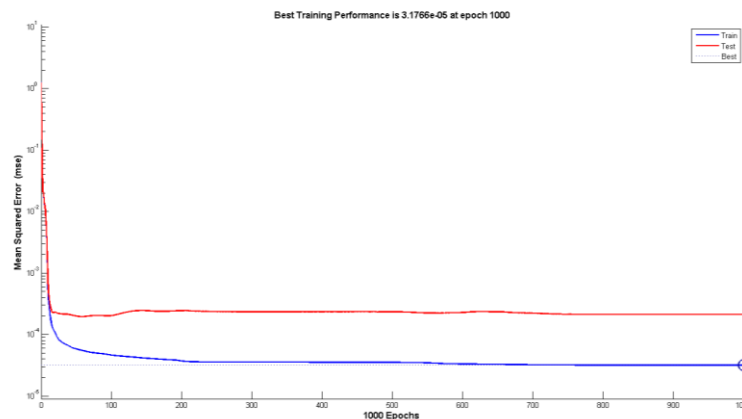


Figura 94 Performance red Br 44n U270.

Elaboración propia






Figura 95. Regresión red Br 44n U270
Elaboración propia

En la figura 96 se observan los resultados del entrenamiento de la red Br 44n, en donde las salidas generadas por la red son las x ; teniendo un menor error para las salidas $T1$, $D1$ y FDS ya que para $T2$ y $D2$ hay resultados que están por debajo del valor real.

Los errores cuadráticos de cada salida se encuentran en la figura 97, donde $T1$, $T2$ y FDS tienen un menor error, con pocos picos en $T1$ y $T2$; ya que éstos se presentan en escasos puntos se puede decir que es ruido en los datos y no afectan en la red en general, lo mismo pasa con FDS , por el contrario el error cuadrático en $D1$ y $D2$ se presenta en muchas de las salidas, lo que indica que la red no aprendió de buena manera estas dos.

El porcentaje de error para cada salida se observa en la figura 98, y éste es muy similar al MSE , siendo casi cero con algunas excepciones para $T1$, $T2$ y FDS y para $D1$ y $D2$ el porcentaje de error es elevado para muchas de las salidas.



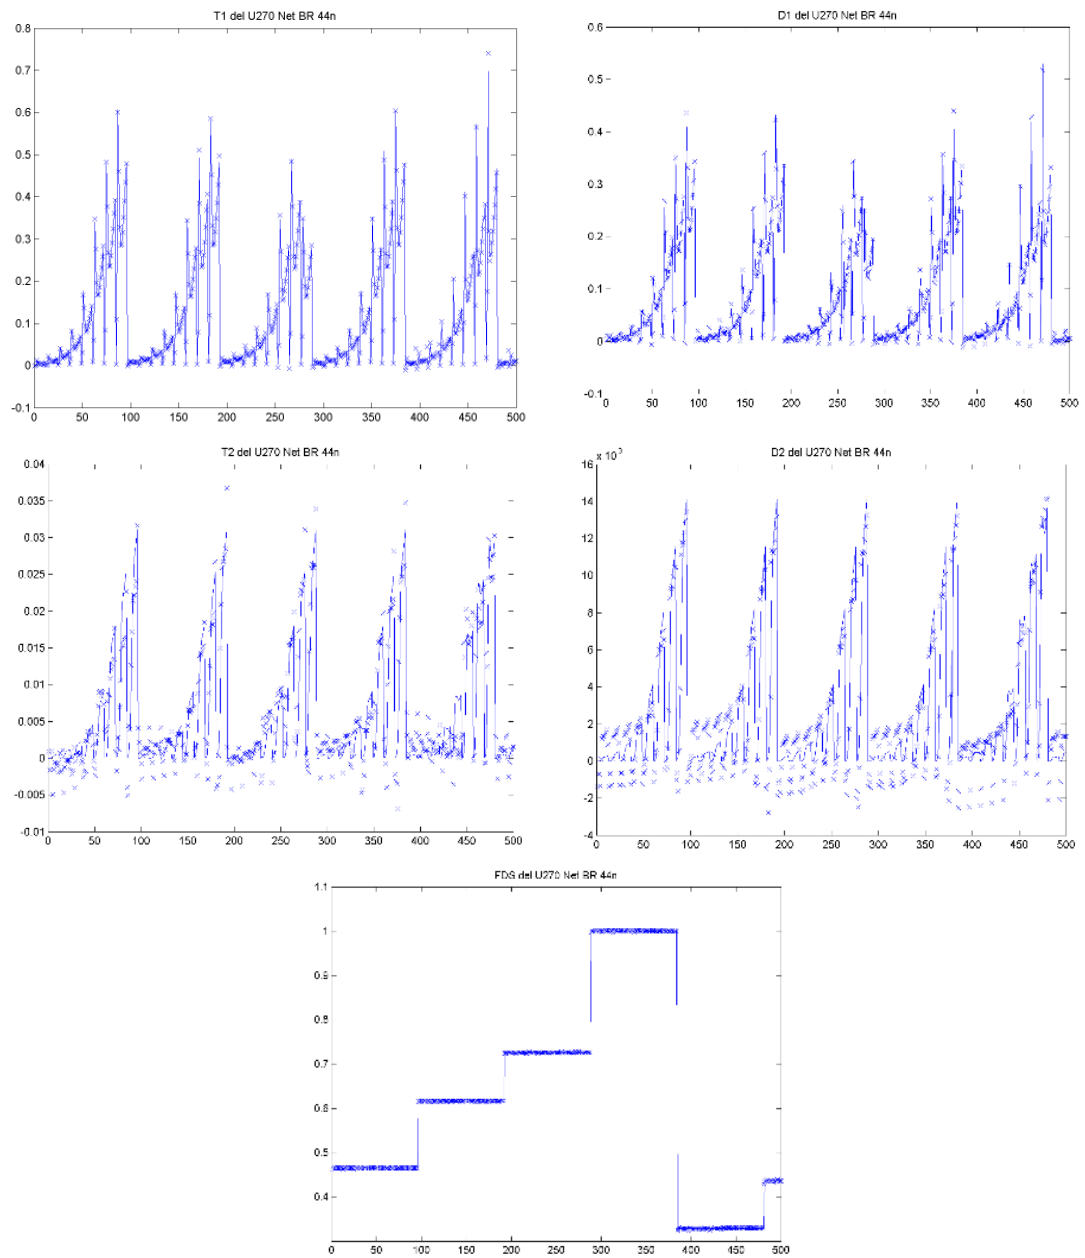


Figura 96. Resultados Net Br 44n U270
Elaboración propia



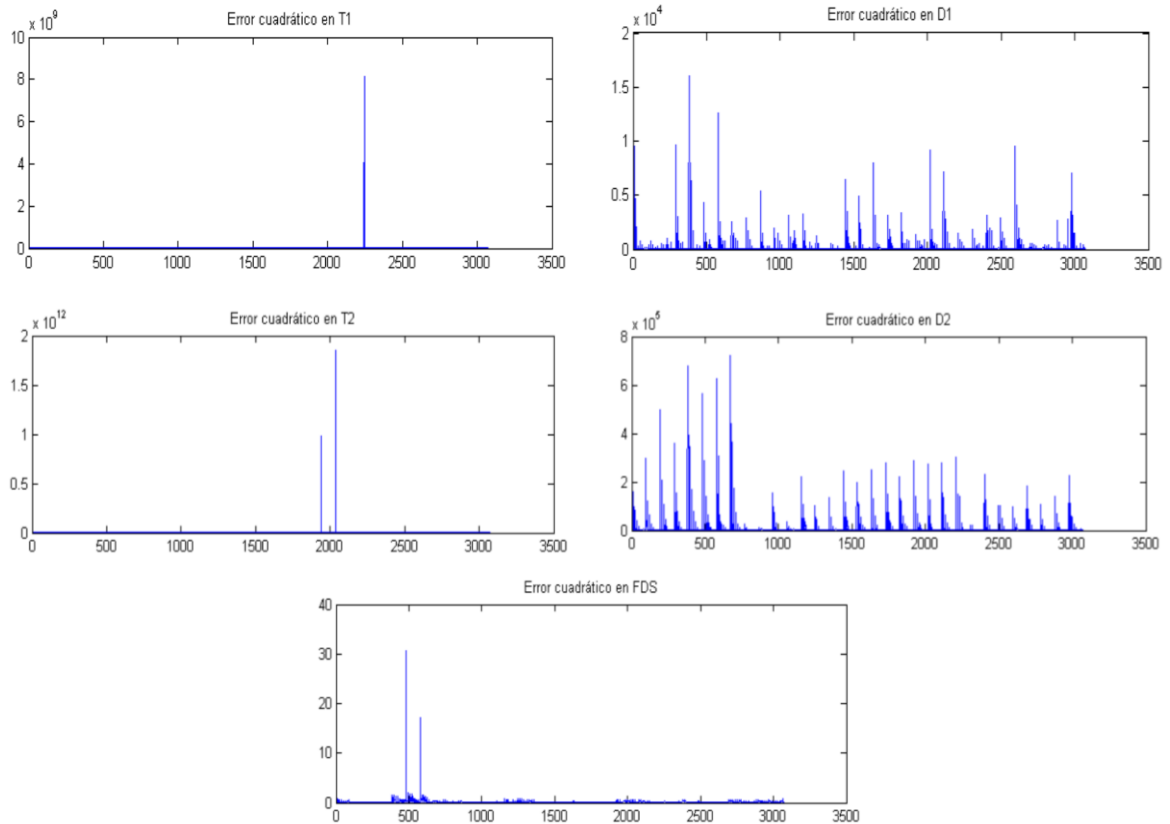


Figura 97. Error cuadrático Net Br 44n U270
Elaboración propia

En las figuras 99 a la 103, se tienen los resultados de la simulación de la red Br 44, con 144 patrones nuevos, de esta manera se puede saber si la red puede predecir los resultados cuando es alimentada con entradas con las que no fue entrenada, en dichas figuras se observa que la red genera salidas que tienen un comportamiento similar a los valores reales, en la salida *FDS* la red no logró seguir la salida real a partir del dato no. 110.



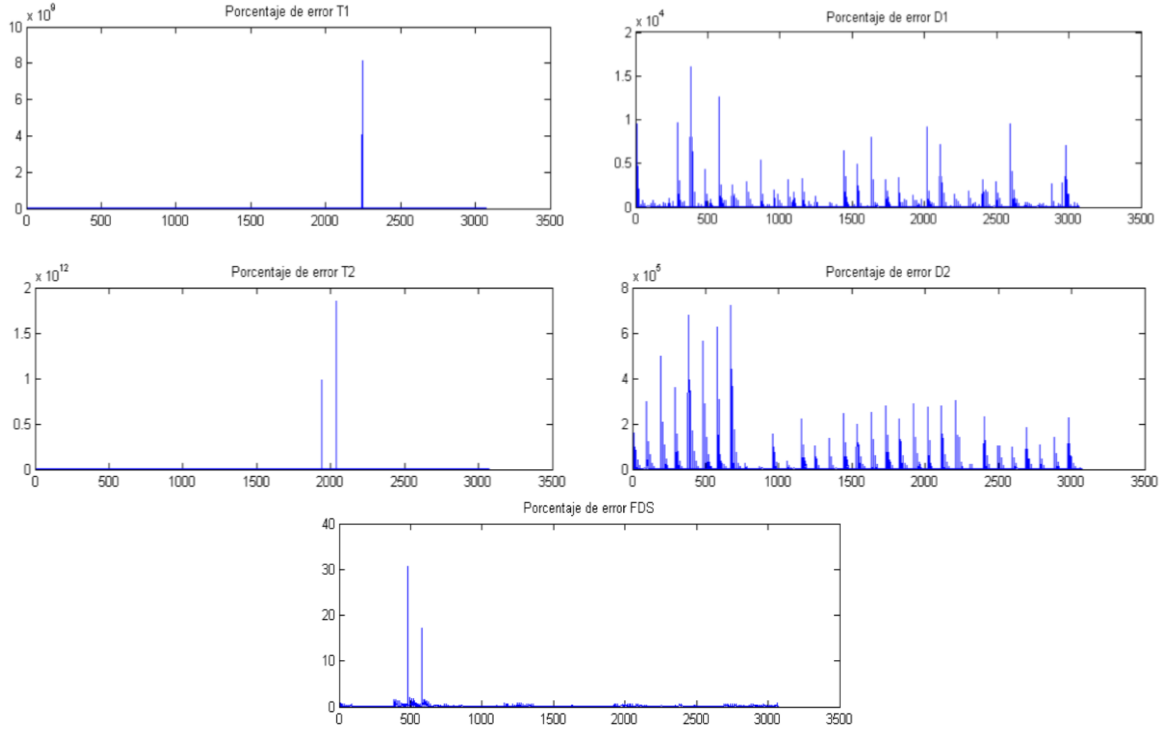


Figura 98. Porcentaje de error Net Br 44n U270
Elaboración propia

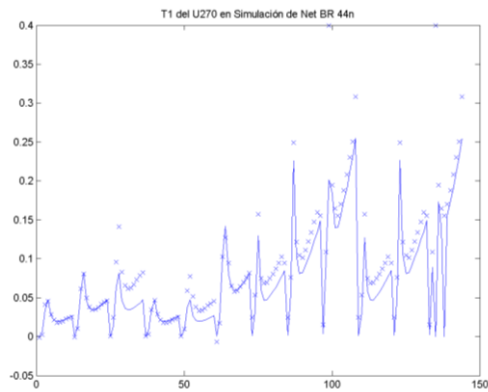


Figura 99. Simulación T1 red Br 44n U270
Elaboración propia




Figura 100. Simulación D1 red Br 44n U270
Elaboración propia






Figura 101. Simulación T2 red Br 44n U270
Elaboración propia




Figura 102. Simulación D2 red Br 44n U270
Elaboración propia




Figura 103. Simulación FDS red Br 44n U270
Elaboración propia

A continuación, se presentan los resultados (tablas 37-48) de las otras redes que se entrenaron.



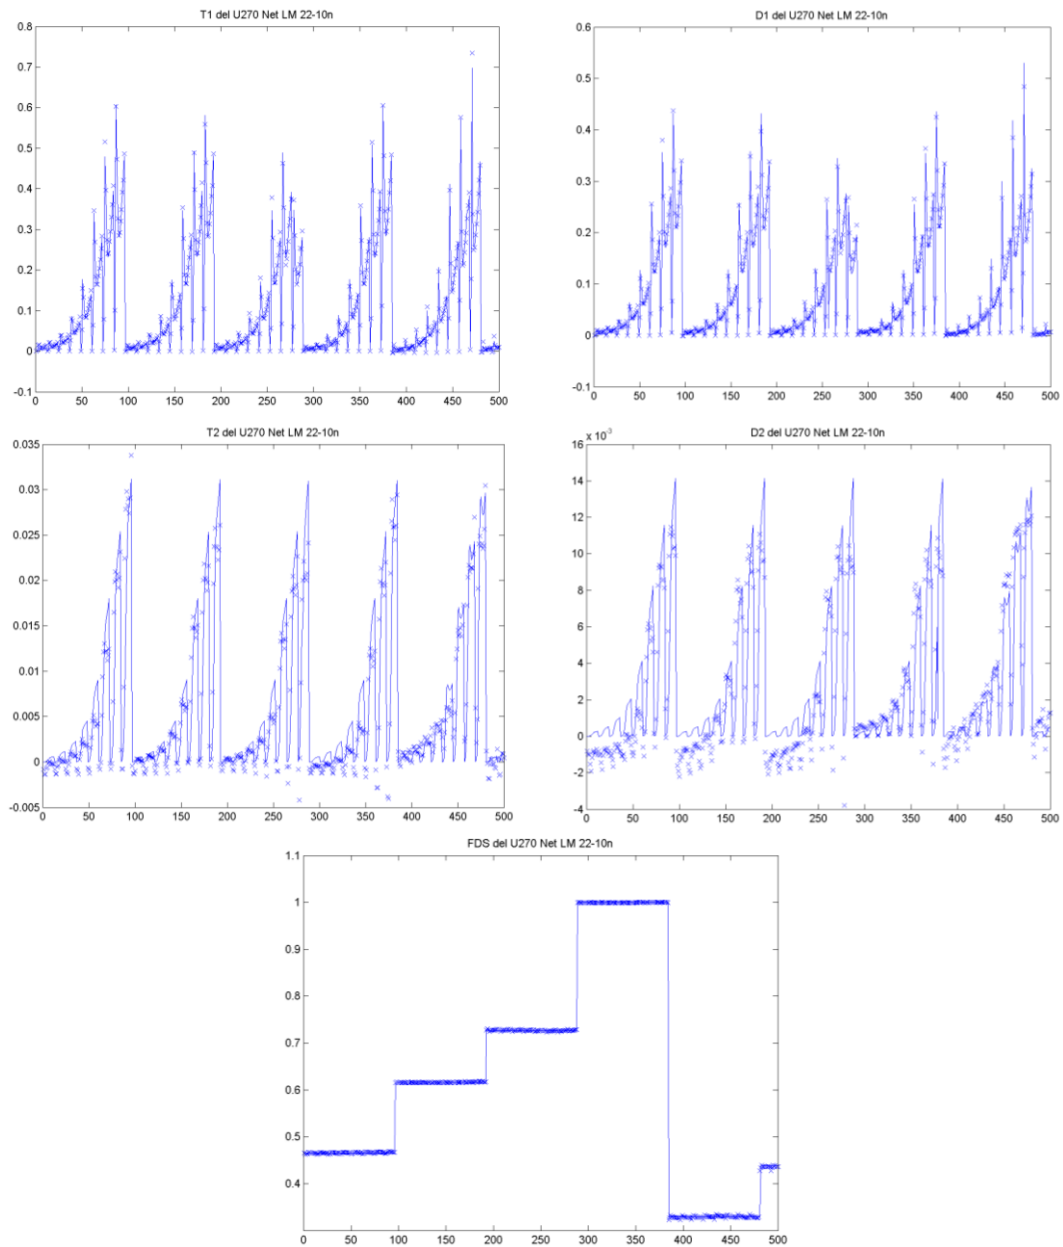


Figura 104. Resultados Net Lm 22-10n U270

Resultados de la red neuronal del modelo U270, con arquitectura de dos capas ocultas con 22 y 10 neuronas en cada una y con un algoritmo de Levenberg-Marquardt.
Elaboración propia



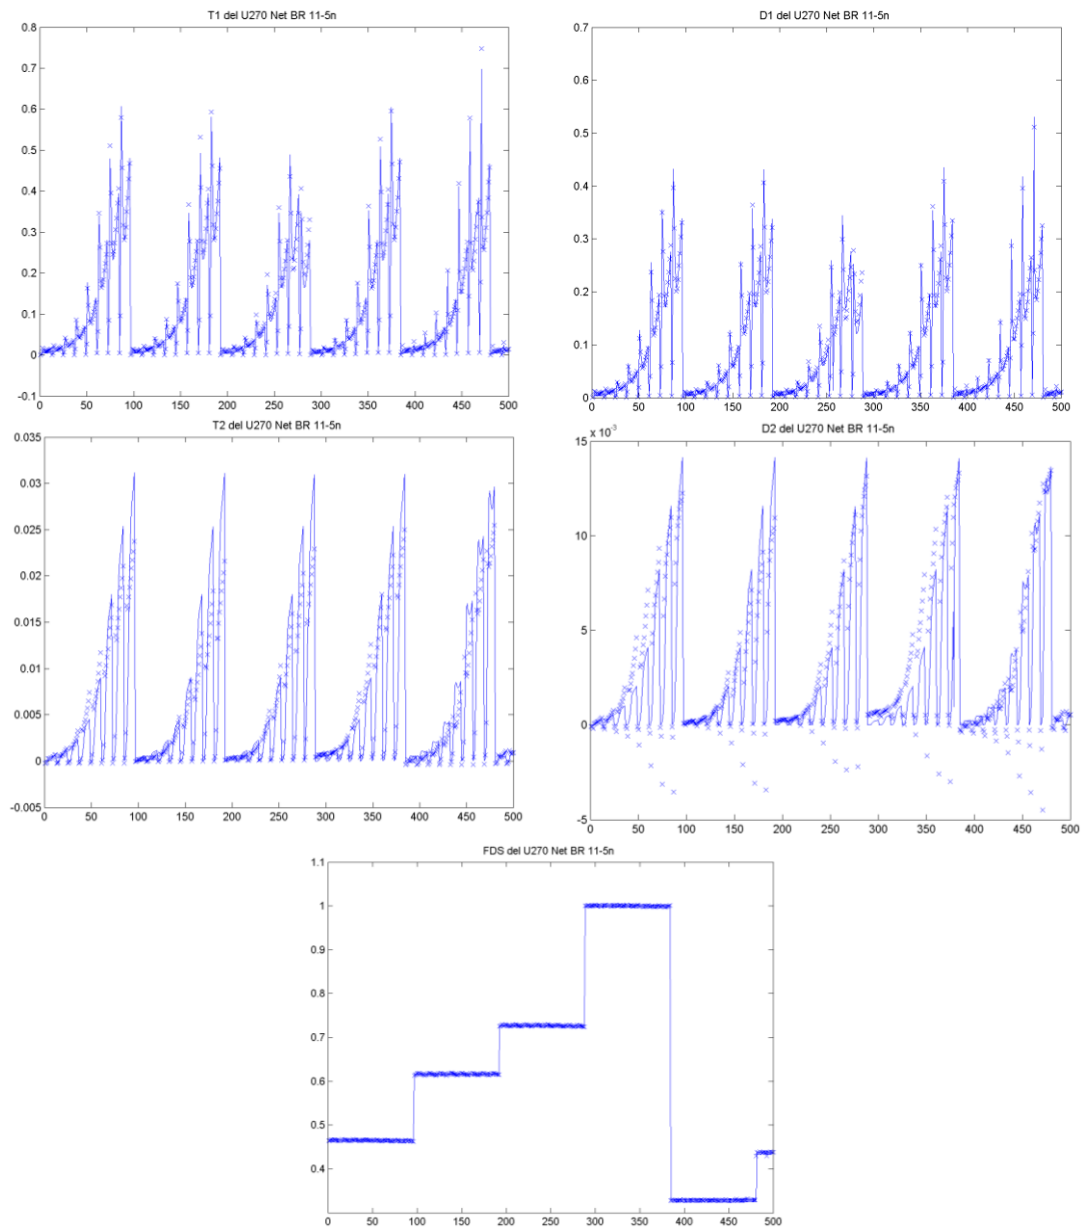


Figura 105. Resultados Net Br 11-5n U270

Resultados de la red neuronal del modelo U270, con arquitectura de dos capas ocultas con 11 y 5 neuronas en cada una y con un algoritmo de Regularización Bayesiana.
Elaboración propia



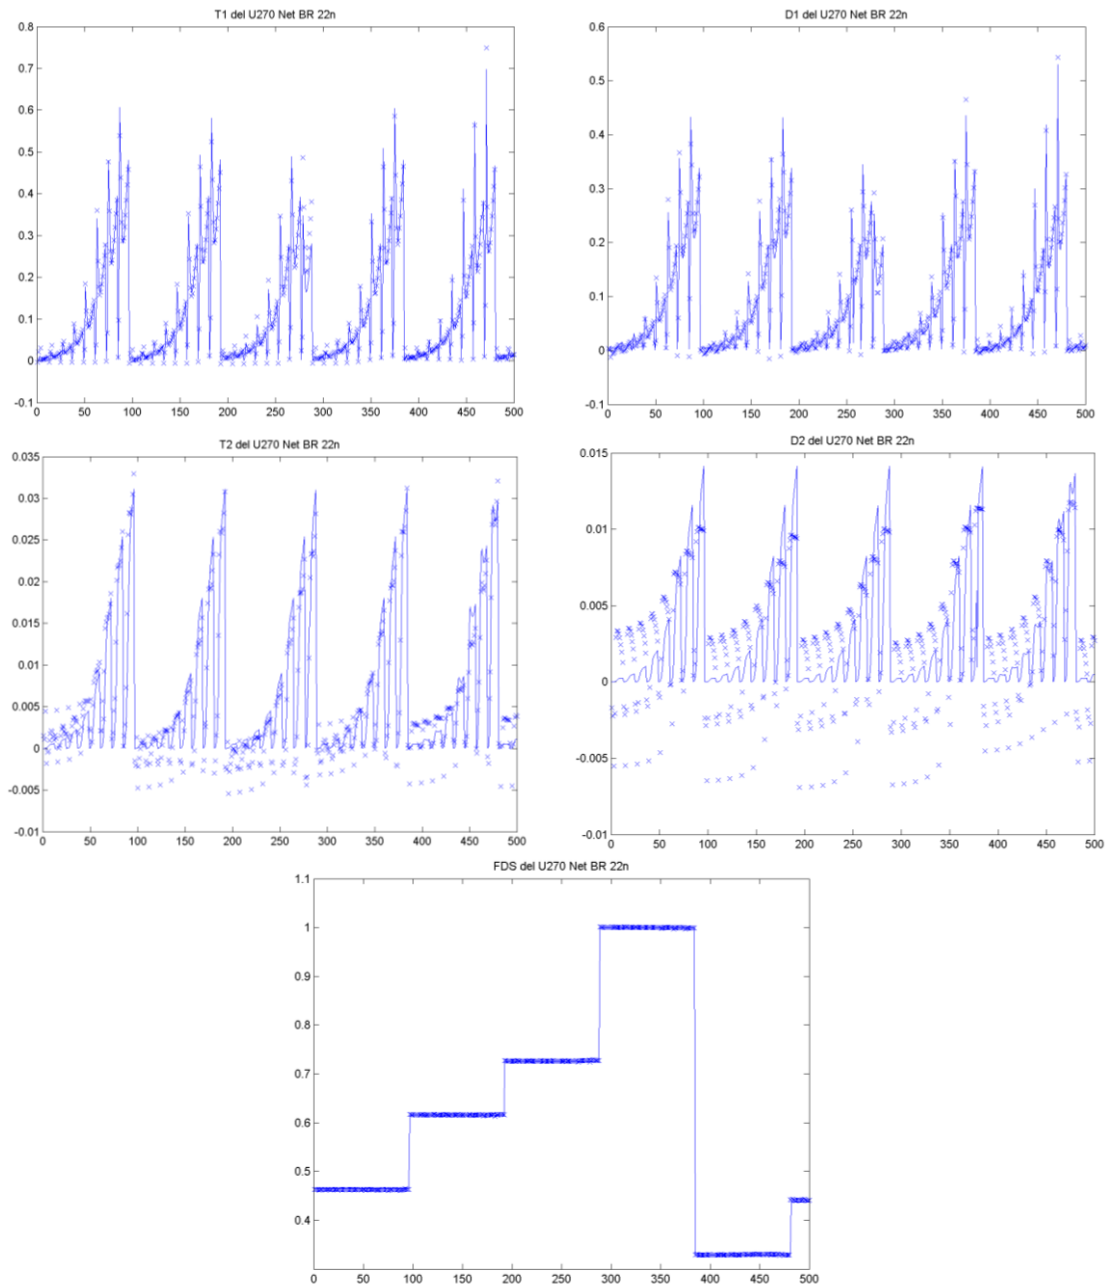


Figura 106. Resultados Net Br 22n U270

Resultados de la red neuronal del modelo U270, con arquitectura de una capa oculta con 22 neuronas y con un algoritmo de Regularización Bayesiana.
Elaboración propia



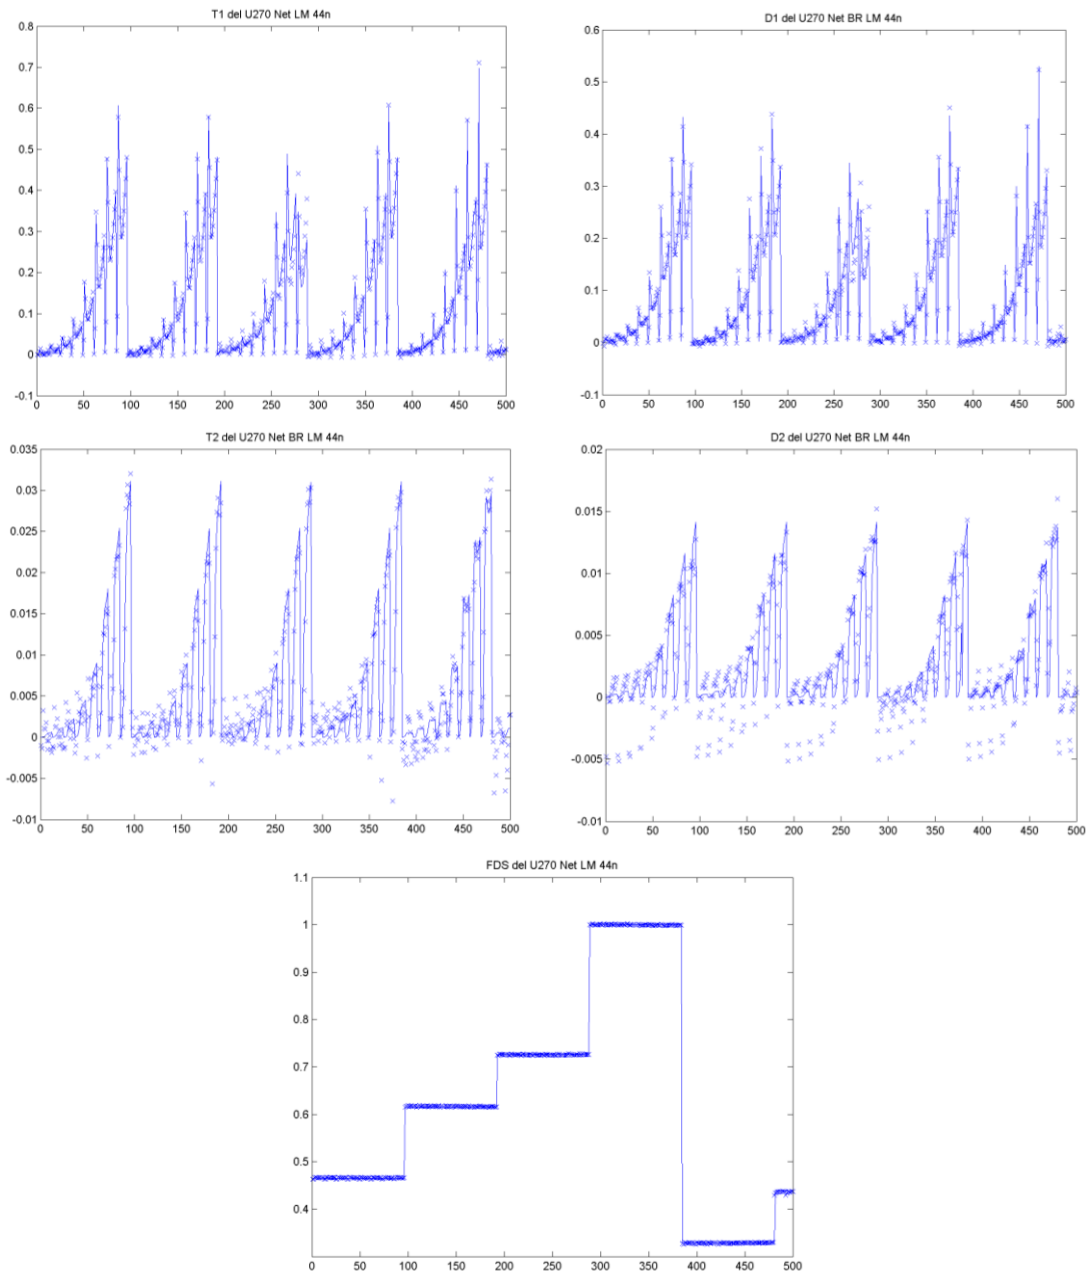


Figura 107. Resultados Net Lm 44n U270

Resultados de la red neuronal del modelo U270, con arquitectura de una capa oculta con 44 neuronas y con un algoritmo de Levenberg-Marquardt.

Elaboración propia



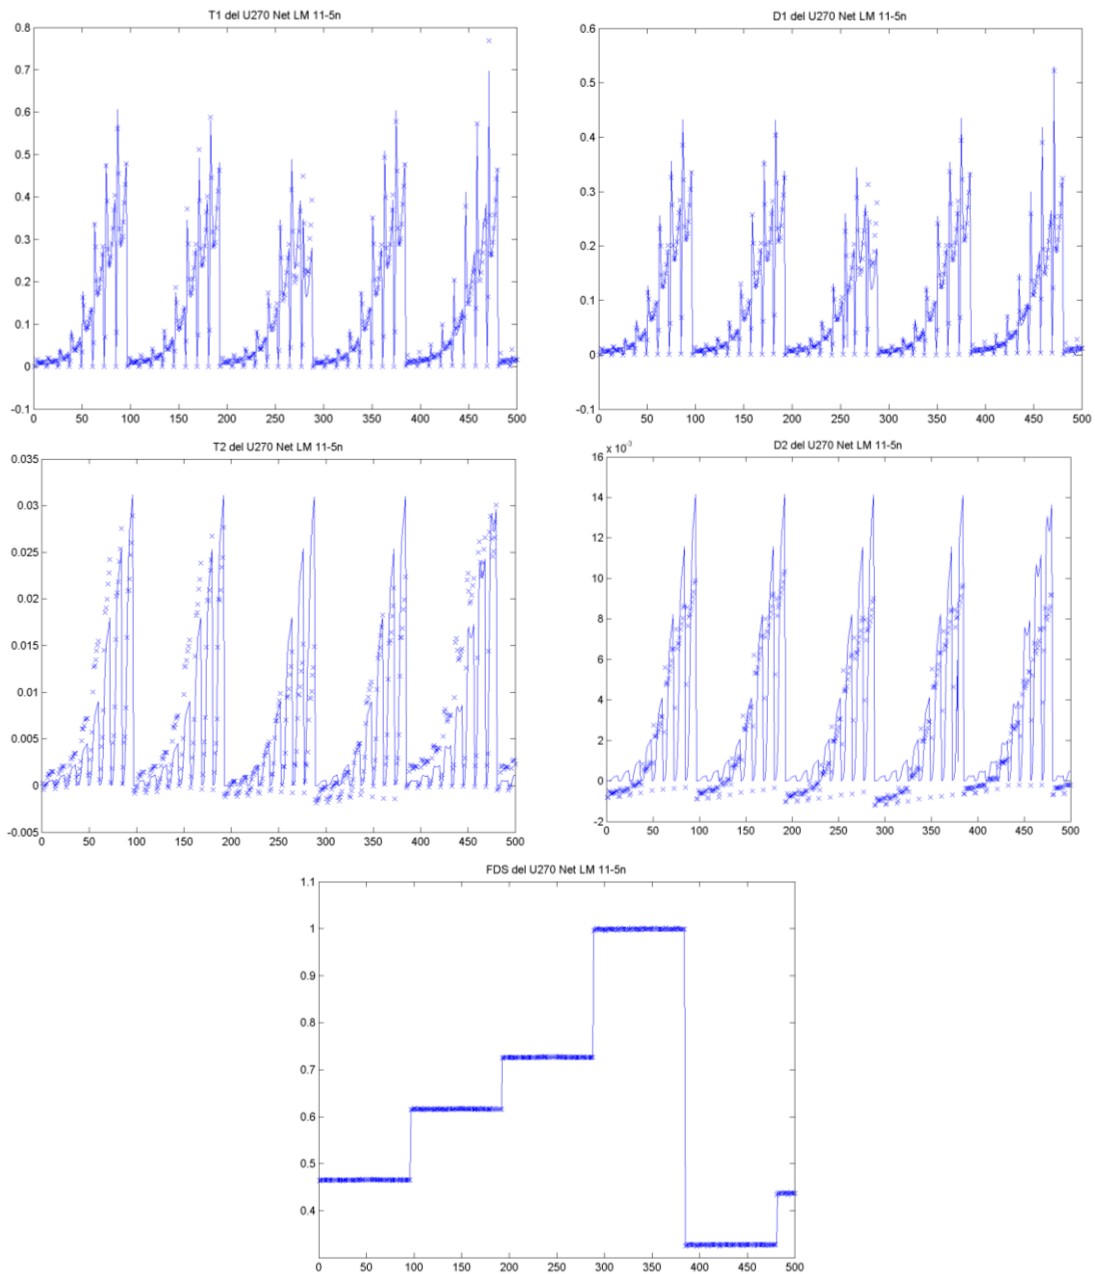


Figura 108. Resultados Net Lm 11-5n U270

Resultados de la red neuronal del modelo U270, con arquitectura de dos capas ocultas con 11 y 5 neuronas en cada una y con un algoritmo de Levenberg-Marquardt.

Elaboración propia



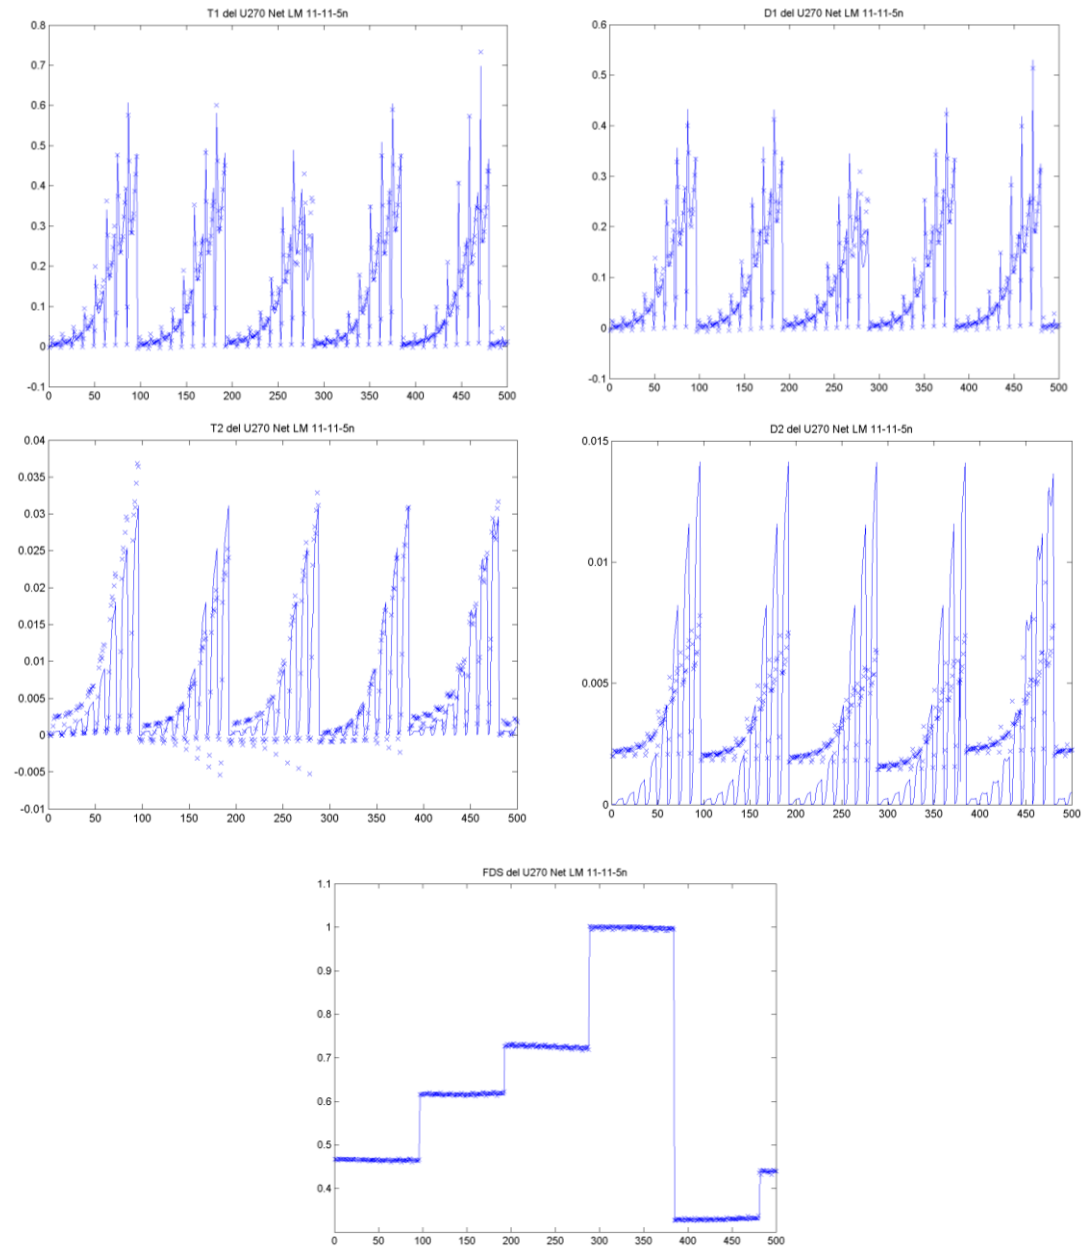


Figura 109. Resultados Net Lm 11-11-5n U270

Resultados de la red neuronal del modelo U170, con arquitectura de tres capas ocultas con 11, 11 y 5 neuronas en cada una y con un algoritmo de Levenberg-Marquardt.

Elaboración propia



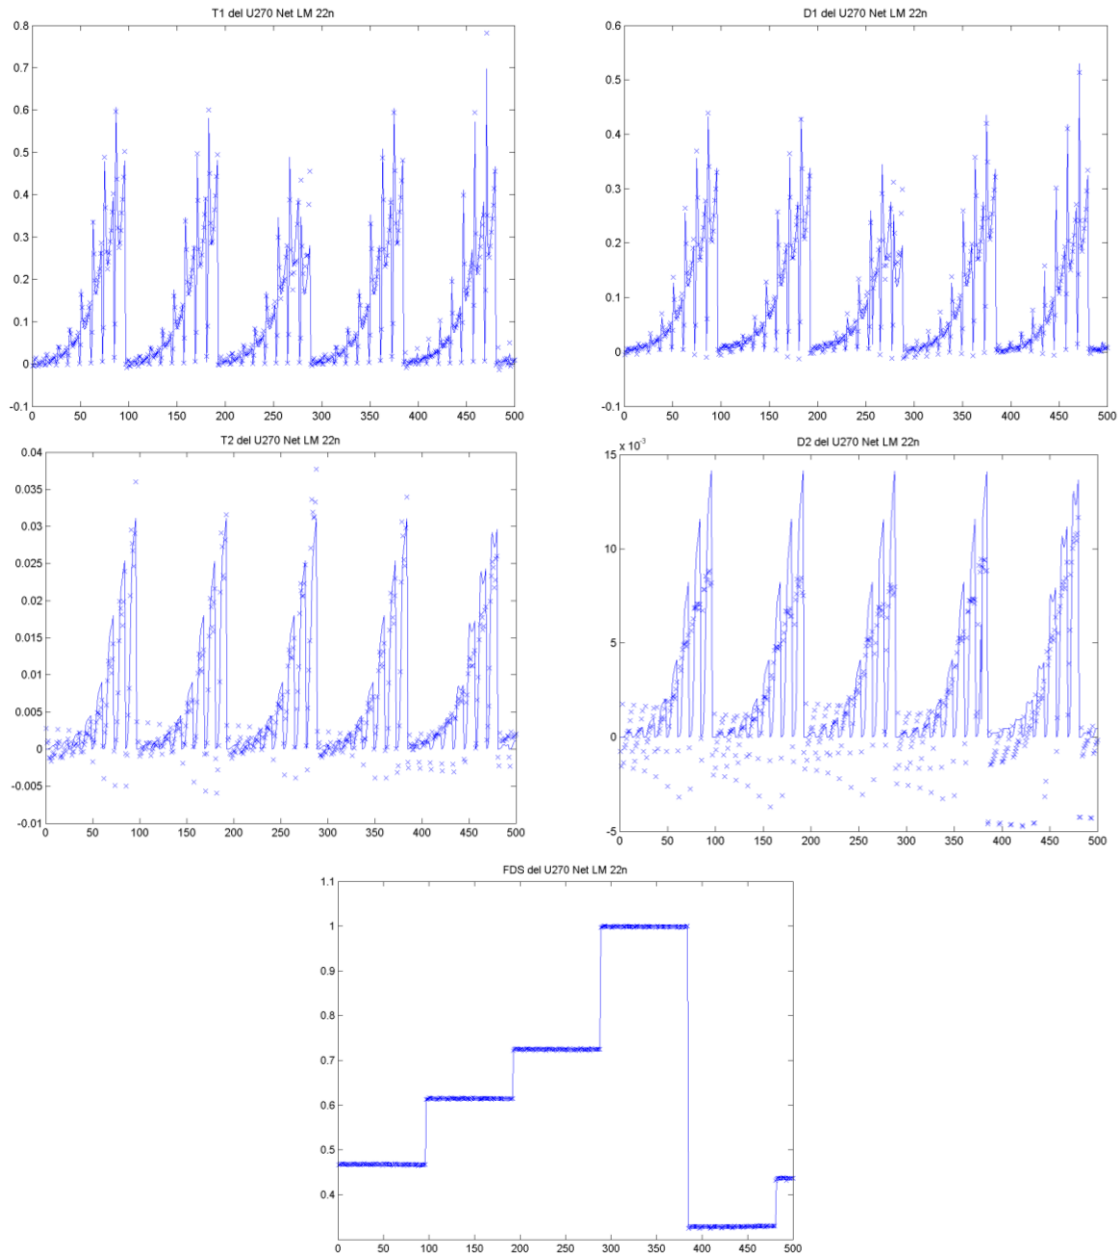


Figura 110. Resultados Net Lm 22n U270

Resultados de la red neuronal del modelo U170, con arquitectura de una capa oculta con 22 neuronas y con un algoritmo de Levenberg-Marquardt.

Elaboración propia



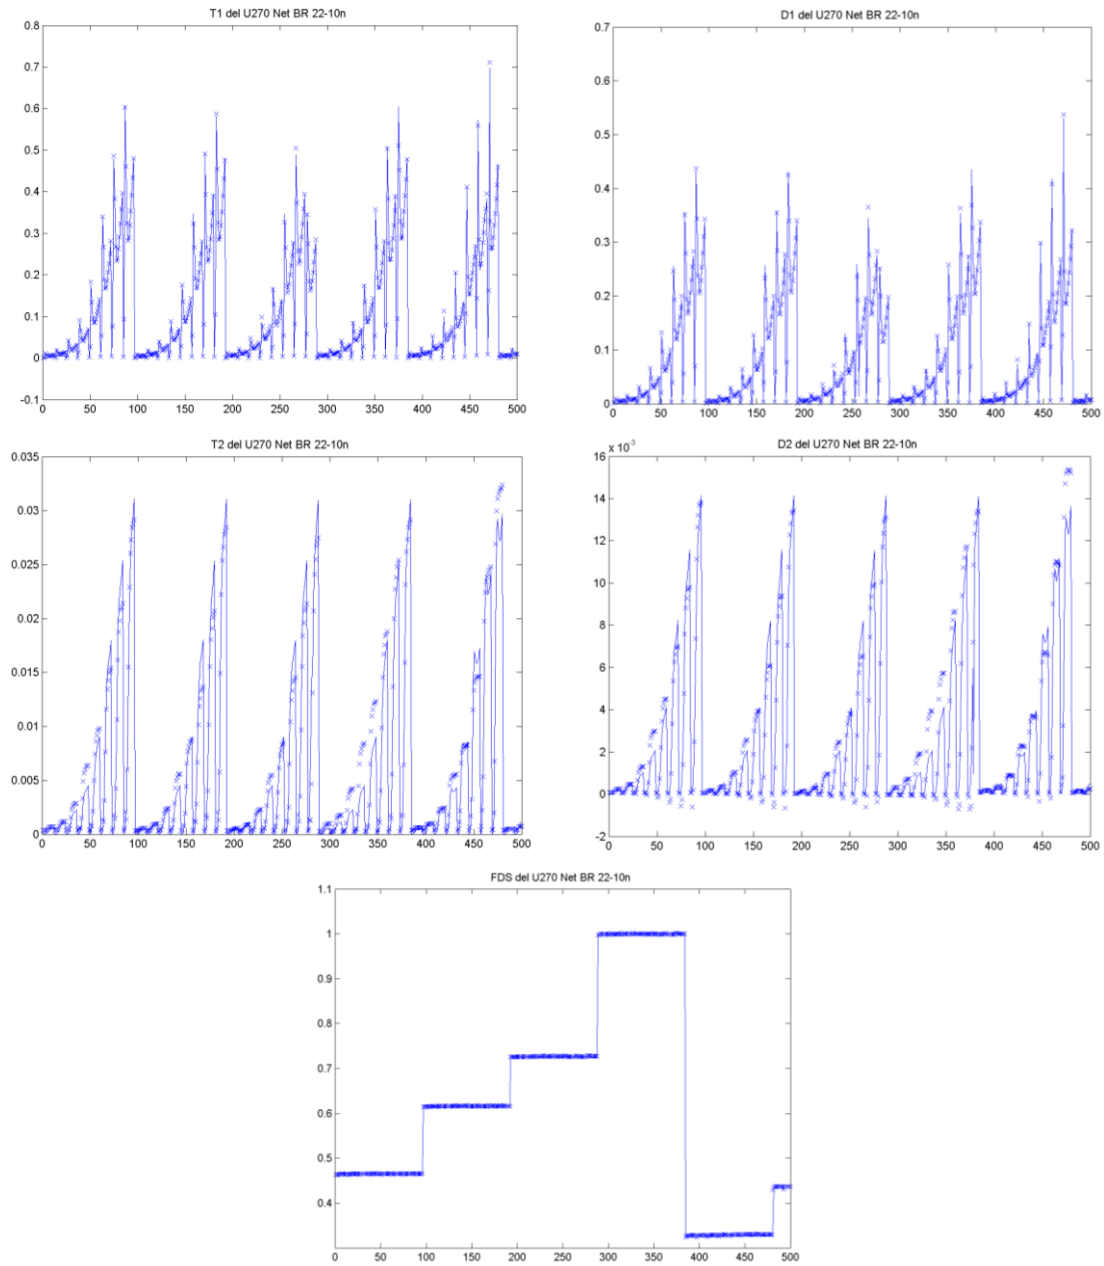


Figura 111. Resultados Net Br 22-10 U270

Resultados de la red neuronal del modelo U270, con arquitectura de dos capas ocultas con 22 y 10 neuronas en cada una y con un algoritmo de Regularización Bayesiana.

Elaboración propia



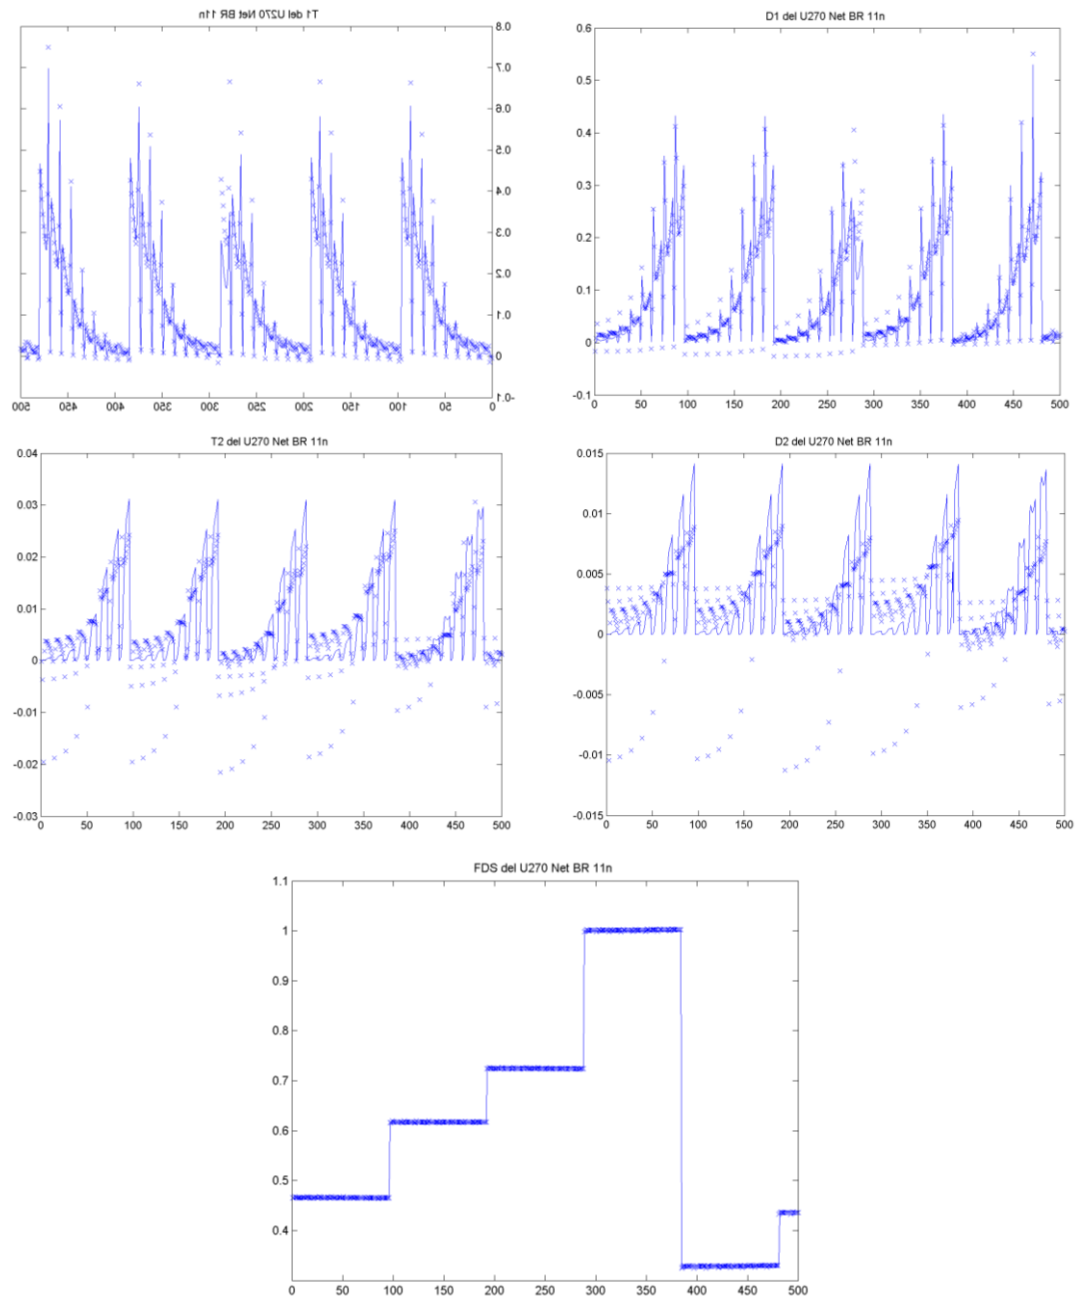


Figura 112. Resultados Net BR 11n U270

Resultados de la red neuronal del modelo U170, con arquitectura de una capa oculta con 11 neuronas y con un algoritmo de Regularización Bayesiana.
Elaboración propia



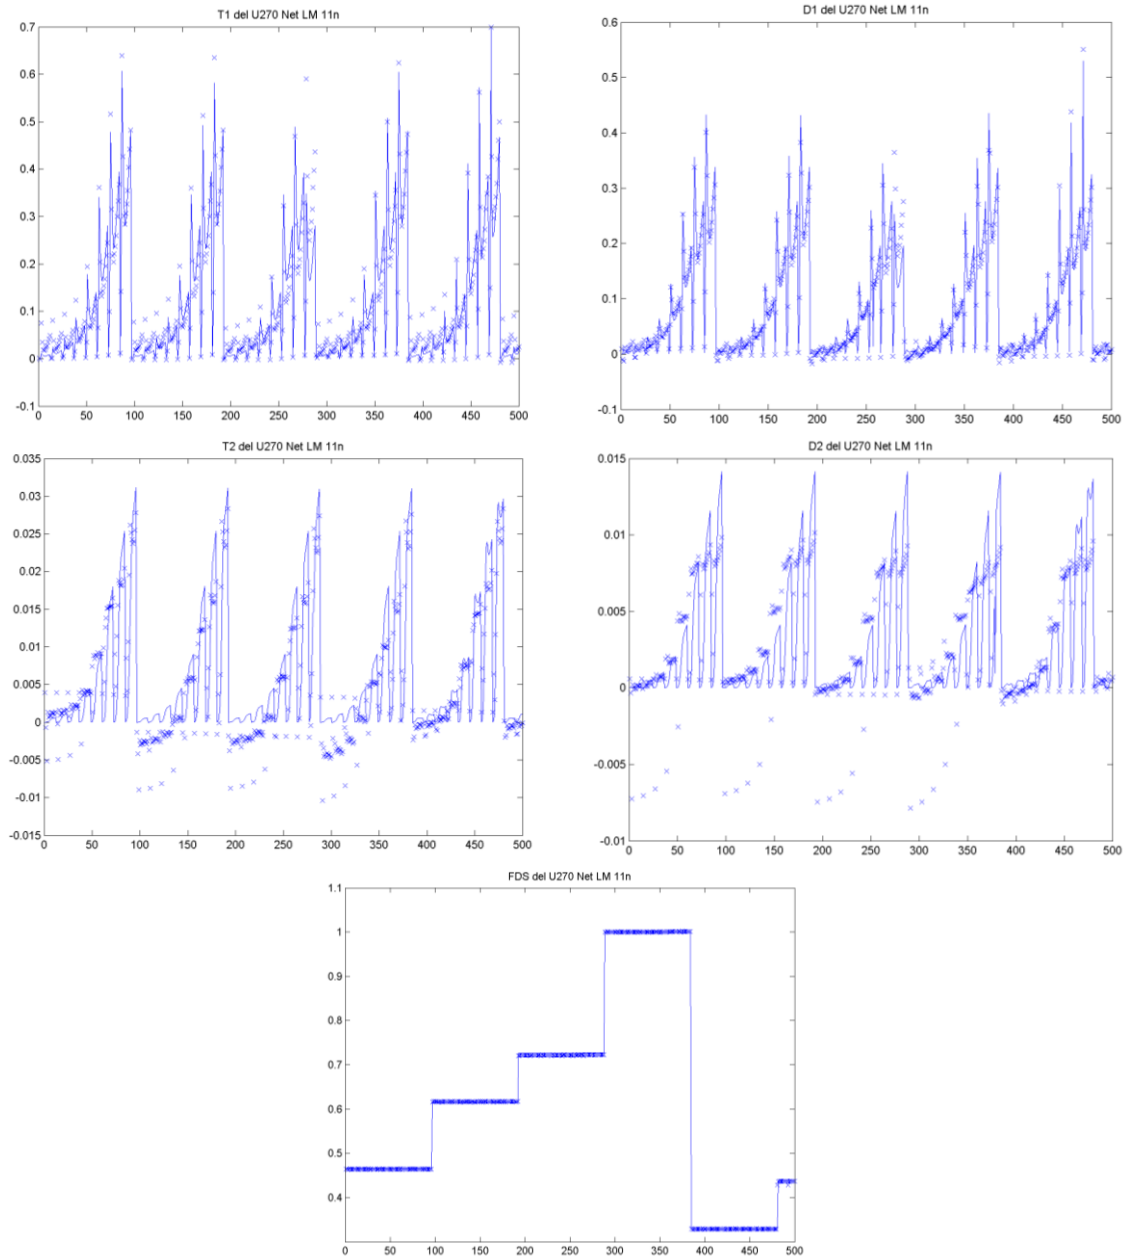


Figura 113. Resultados Net Lm 11 U270

Resultados de la red neuronal del modelo U170, con arquitectura de una capa oculta con 11 neuronas y con un algoritmo de Levenberg-Marquardt.

Elaboración propia



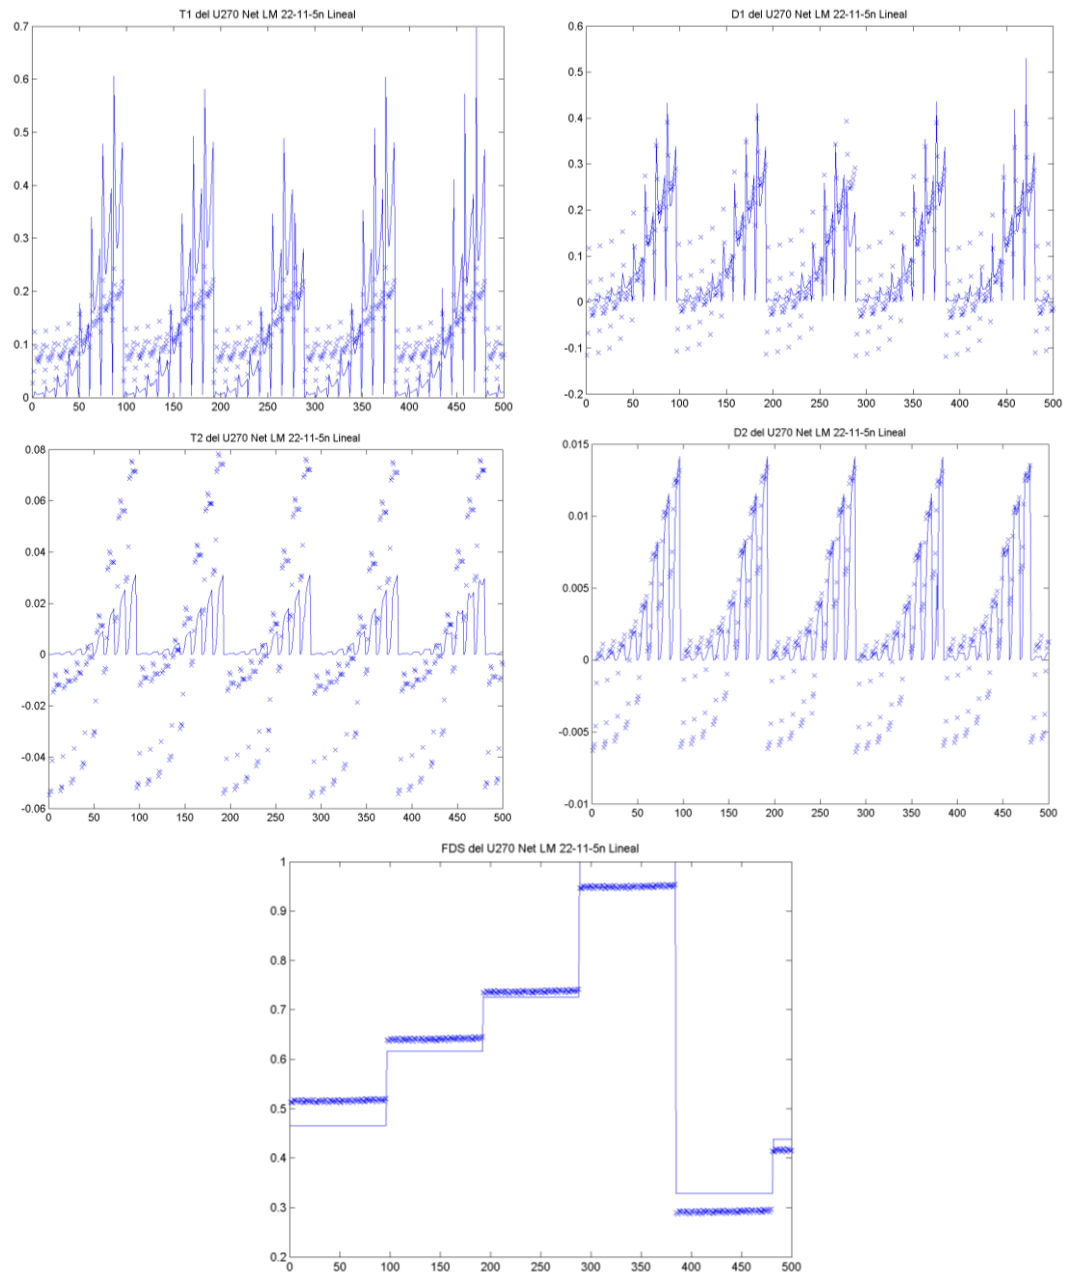


Figura 114. Resultados Net Lm 22-11-5n PURELINE U270

Resultados de la red neuronal del modelo U170, con arquitectura de tres capas ocultas con 22, 11 y 5 neuronas en cada una y función de activación PURELINE y con un algoritmo de Levenberg-Marquardt.
Elaboración propia



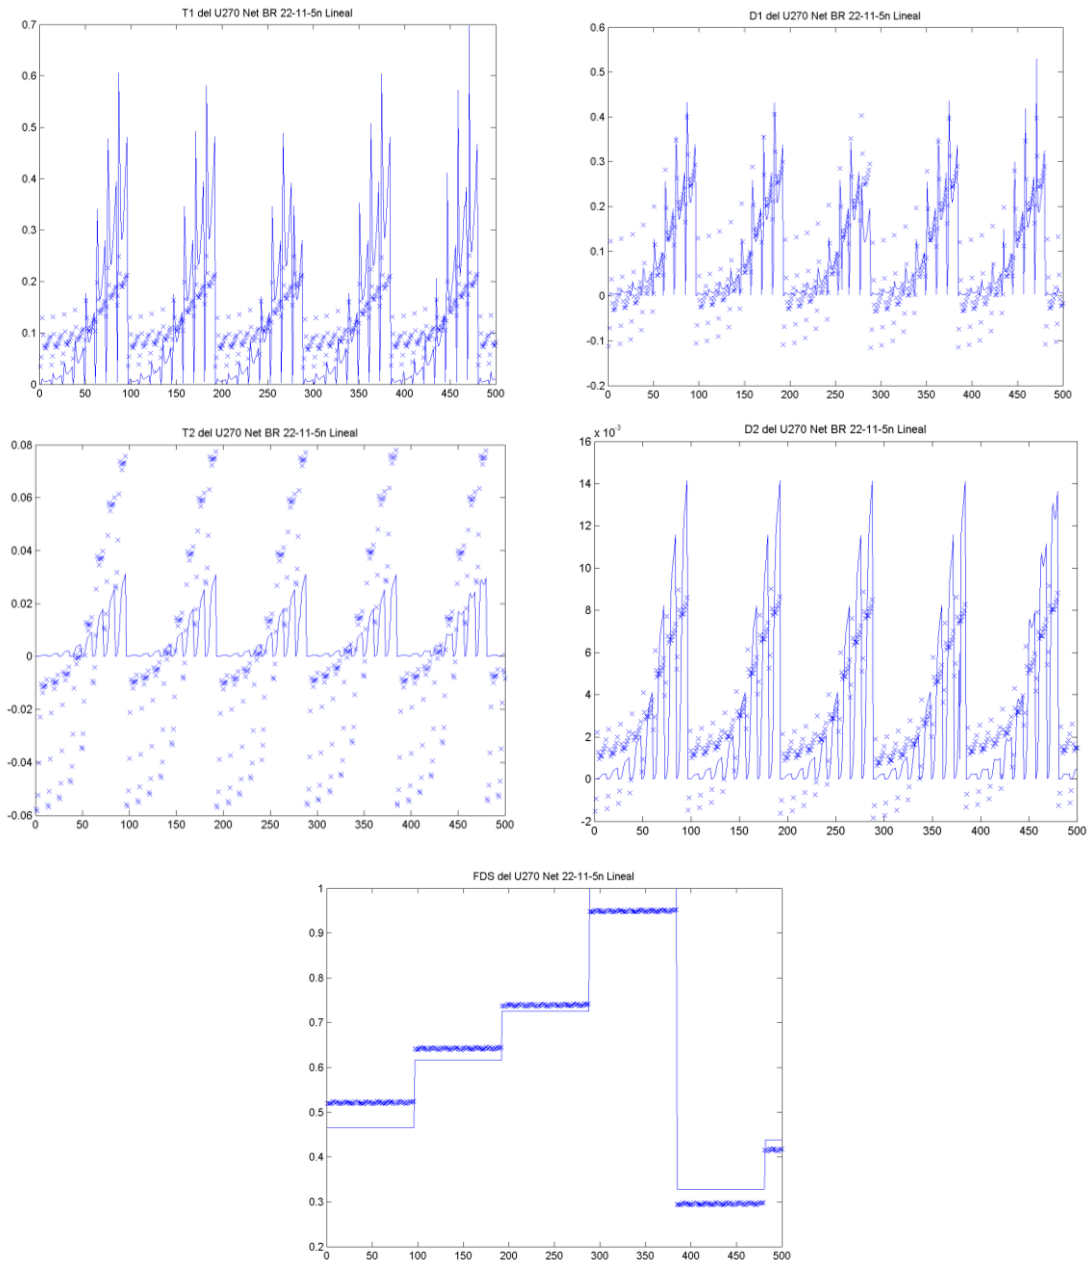


Figura 115. Resultados Net Br 22-11-5n PURELINE U270

Resultados de la red neuronal del modelo U170, con arquitectura de tres capas ocultas con 22, 11 y 5 neuronas en cada una y función de activación PURELINE y con un algoritmo de Regularización Bayesiana.

Elaboración propia





También se realizó el experimento de separar las salidas 1 y 2 de las 3, 4 y 5 en redes diferentes con la finalidad de mejorar el resultado que dio la red Br 44n del U270. En la tabla 23 se presenta el *MSE* y el *r* de ambas redes. La red con las salidas *T2, D2* y *FDS* tuvo un mejor entrenamiento, con un $MSE = 1.95E - 05$ y un $R = 0.999$.

No. Red	Red	<i>MSE</i>	<i>R</i>	<i>MSE</i>	<i>R</i>
		T1 y D1		T2, D2 y FDS	
1	BR 22	1.90E-04	0.9933	1.95E-05	0.9999

Tabla 23. MSE y R Net BR 22n Salidas separadas U170
 Elaboración propia

Se comparan (tabla 24) los resultados obtenidos de estas dos redes separadas, con salidas separadas y con la que tuvo el menor *MSE* teniendo las 5 salidas con el primer lugar del U270, para saber cuál tiene mejor comportamiento. Estos datos se encuentran graficados dentro de las figuras 116 y 117, en ellas se tiene que la red para *T2, D2* y *FDS*, tienen un *MSE* más pequeño y un mayor *r*, lo que la coloca como la mejor, sin embargo, la red BR 44n supera los resultados de la red que tienen a *T1* y *D1* con un mejor *MSE* y un *R* más alto. Los resultados de las redes con salidas separadas se encuentran en las figuras 118-122, *T1, D1* y *FDS* presentan un buen comportamiento, generando salidas muy cercanas al valor real, mientras que en *T2* y *D2* se tienen salidas con un valor lejano al real.

No. Red	Red	Error cuadrático medio	Coefficiente de correlación
1	Br 22 T1 y D1	1.90E-04	0.9933
2	Br 22 T2, D2 y FDS	1.95E-05	0.9999
3	Br 44 (Todas las salidas)	5.86E-05	0.9995

Tabla 24. Comparación de MSE y r entre red con salidas separadas y la BR 44 del U270
 Elaboración propia






Figura 116. Comparación de MSE U270
Elaboración propia




Figura 117. Comparación de R U270
Elaboración propia




Figura 118. T1 Net Br 22n salidas separadas U270
Elaboración propia




Figura 119. D1 Net Br 22n salidas separadas U270
Elaboración propia






Figura 120. T2 Net Br 22n salidas separadas U270

Elaboración propia




Figura 121. D2 Net Br 22n salidas separadas U270

Elaboración propia




Figura 122. FDS Net Br 22n salidas separadas U270

Elaboración propia

3.2.2 Redes entrenadas usando Python

En esta sección se presentan experimentos que se llevaron a cabo con el uso del lenguaje de programación Python y las librerías de Keras para el entrenamiento de redes neuronales y tener el resultado de las mismas en un ambiente diferente a Matlab. En un inicio se podría decir que los resultados deben de ser similares tanto en Matlab como en Python.

3.2.2.1 Redes Python para el U170

En la tabla 25 se enlistan las redes neuronales que fueron entrenadas para el U170, el número de capas ocultas, las neuronas en ellas, la función de actuación utilizada y el algoritmo para reducir el error, la primer red abarca las 5 salidas originales, teniendo una exactitud del 98% (una de las





ventajas de Keras es que en automático genera el valor del *Accuracy* al final de cada entrenamiento), las otras dos redes tienen salidas separadas, al igual que en Matlab, la exactitud obtenida fue de 98 y 100%.

No.	Capas	Neuronas	Función de activación	Algoritmo de aprendizaje	Salidas	Exactitud
1	1	22	Sigmoid	Gradiente por descenso	Todas (T1, D1, T2, D2 y FDS)	98%
2	1	22	Sigmoid	Gradiente por descenso	T1 y D1	98%
3	1	22	Sigmoid	Gradiente por descenso	T2, D2 y FDS	100%

Tabla 25. Redes en Python U170
Elaboración propia




Figura 123. Performance Net 22n GD U170

En esta figura se observa el número de épocas y como el error disminuye aumentando la exactitud, alcanzando su máximo a partir de la época 30.

Elaboración propia



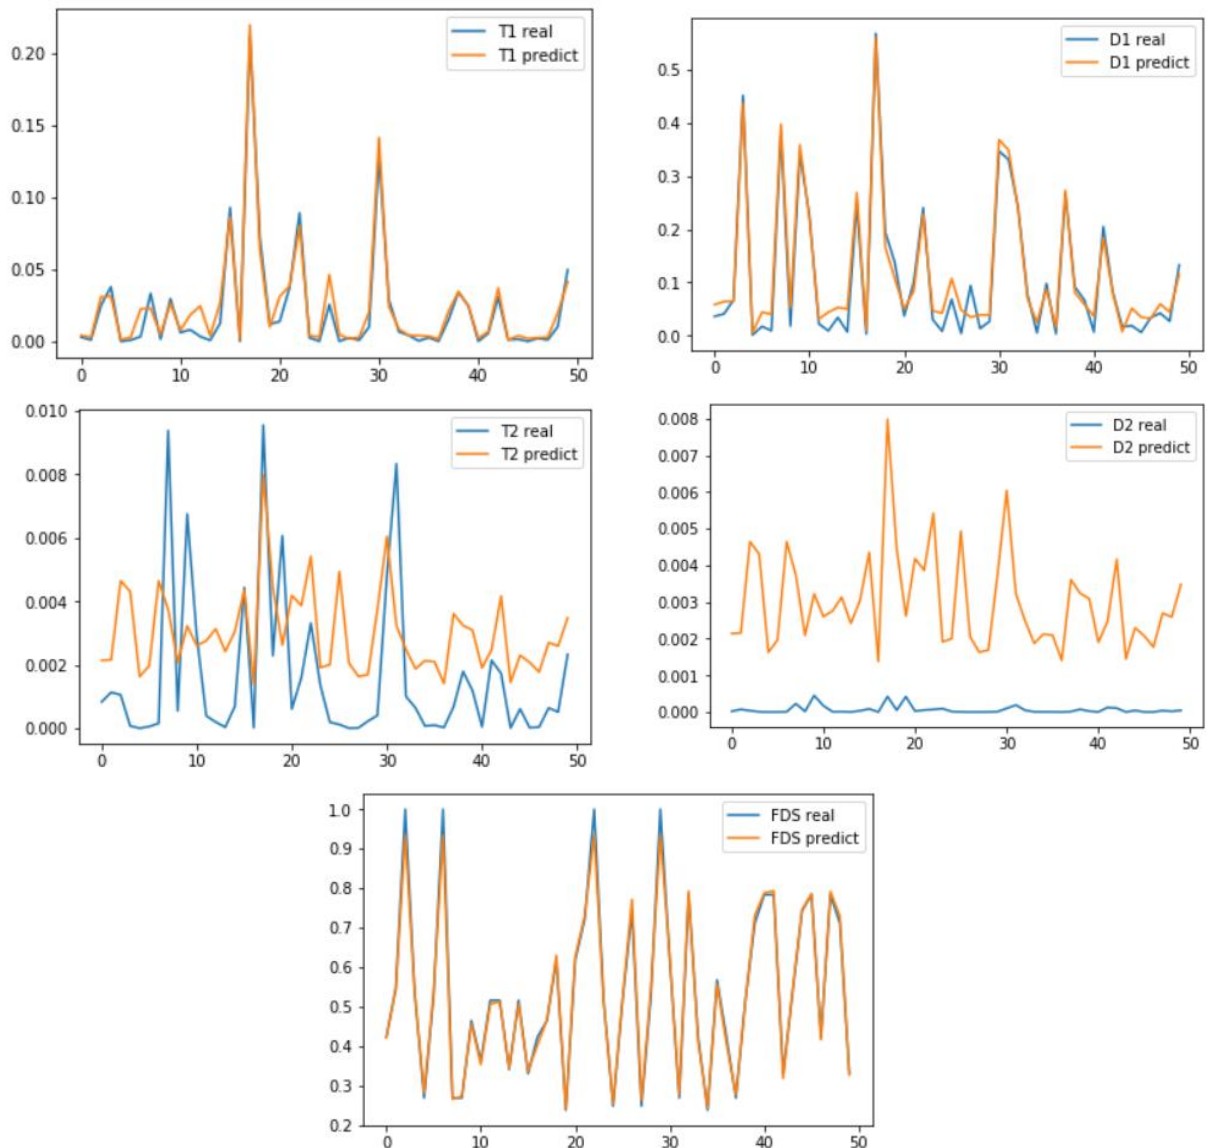


Figura 124. Red 22n GD Python U170

En la tabla se tienen las salidas generadas por la red con una sola capa oculta de 22 neuronas, con una función de activación sigmoide y el algoritmo de gradiente por descenso. Donde la línea de color azul son los valores reales y la naranja el resultado de la red.

Elaboración propia



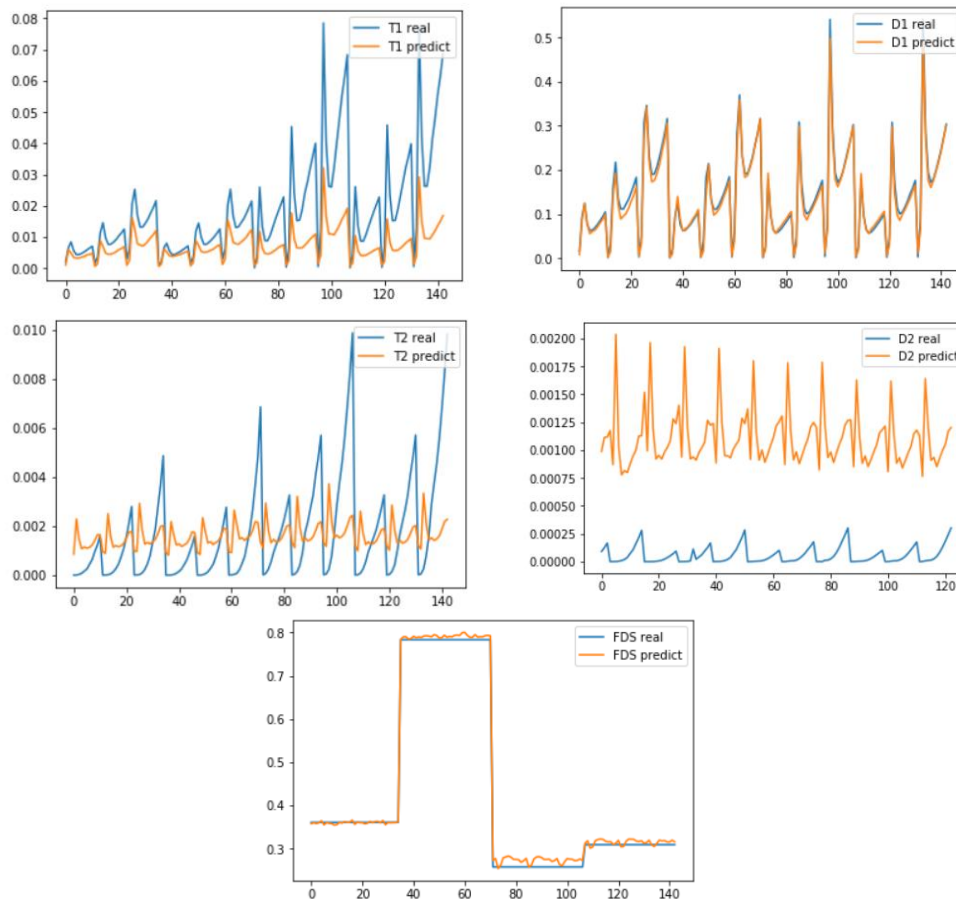


Figura 125. Simulación red 22n GD U170

Se muestran las salidas generadas de la red anterior, usando 120 datos diferentes a los del entrenamiento. Donde la línea de color azul son los valores reales y la naranja el resultado de la red.

Elaboración propia




Figura 126. Performance de las redes 22n GD con salidas separadas U170

En esta tabla se muestra el performance de dos redes, cada una con una capa oculta de 22 neuronas, con una función de activación sigmoide y el algoritmo de gradiente por descenso. Se tiene como la exactitud aumenta en cada época de entrenamiento, la gráfica del lado izquierdo tiene la salida T1 y D1, mientras que en la de la derecha se tienen T2, D2 y FDS.

Elaboración propia



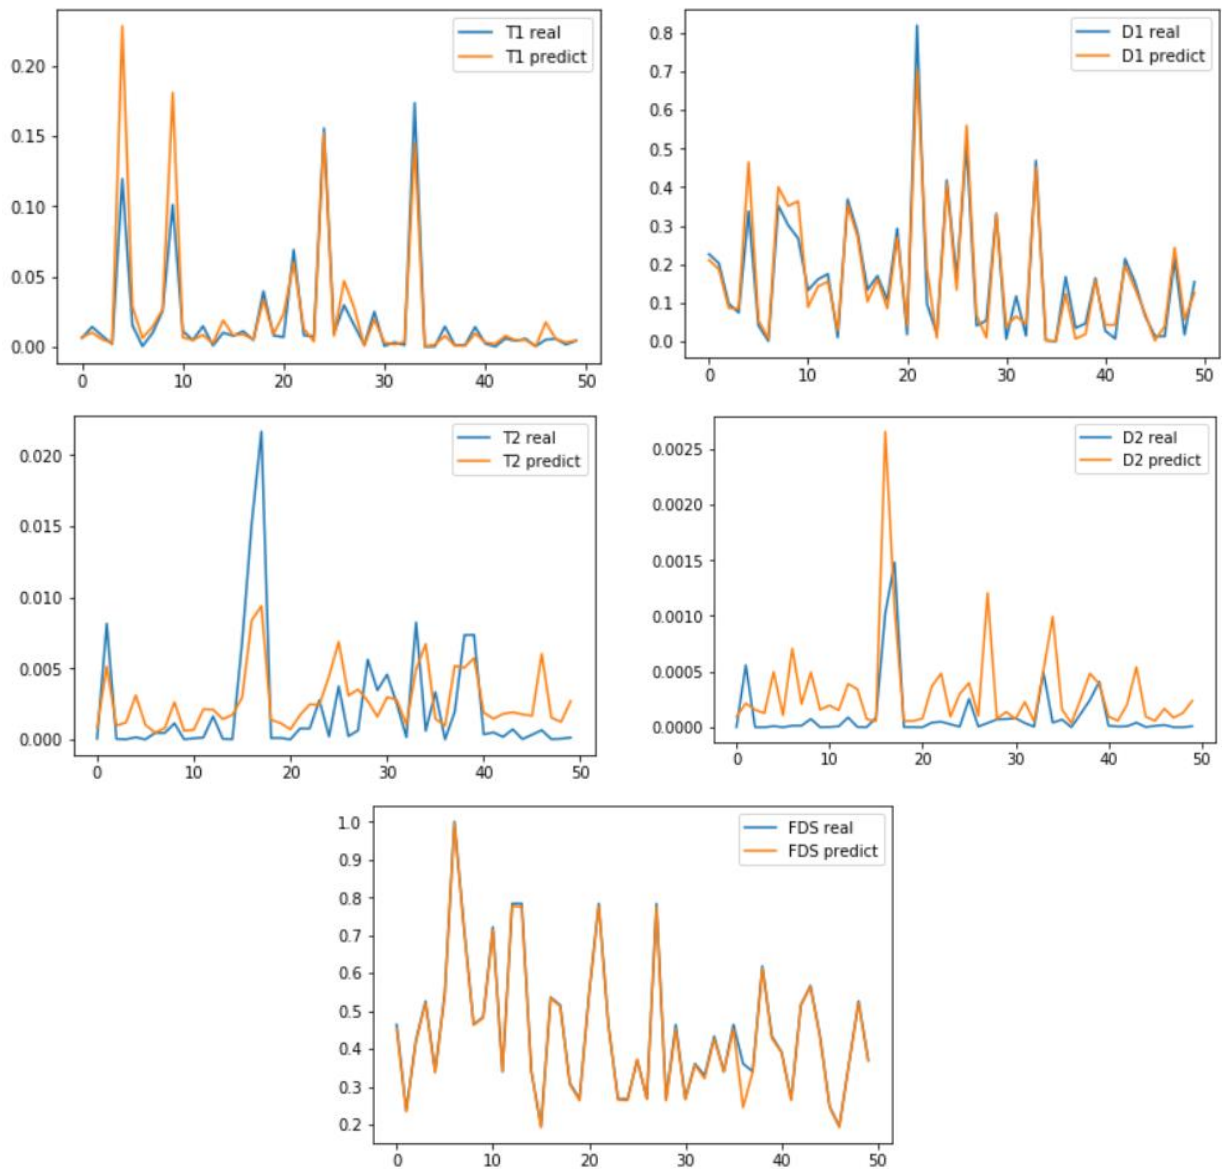


Figura 127. Red 22n GD Python salidas separadas U170

En la tabla se tienen las salidas generadas por las dos redes con una sola capa oculta de 22 neuronas, con una función de activación sigmoide y el algoritmo de gradiente por descenso. Donde la línea de color azul son los valores reales y la naranja el resultado de la red.

Elaboración propia



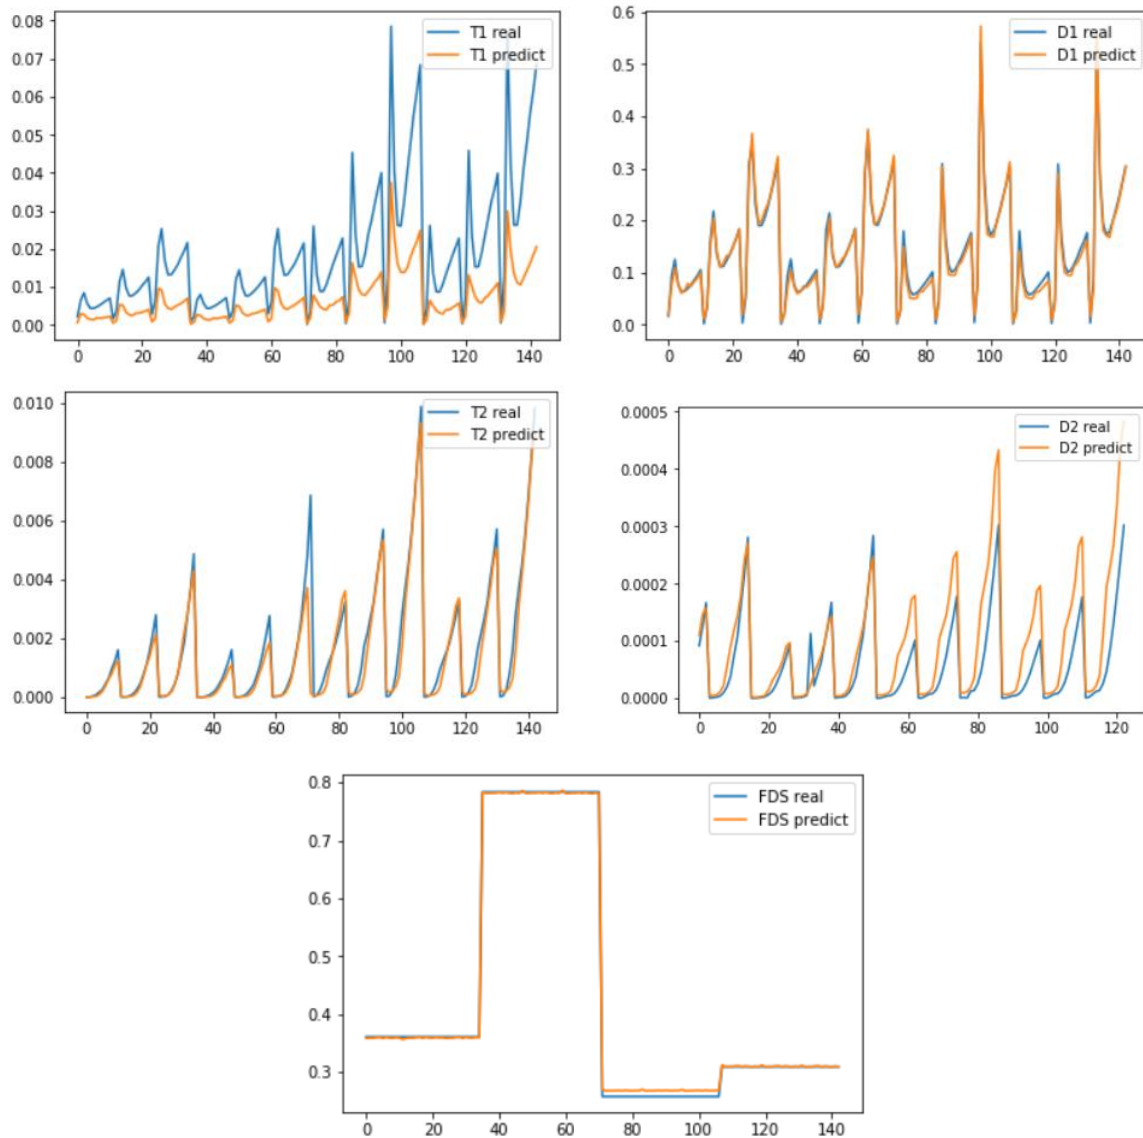


Figura 128. Simulación de Red 22n GD Python salidas separadas UI70

Se muestran las salidas generadas por las redes que se entrenaron con 2 y 3 salidas, usando 120 datos diferentes a los del entrenamiento. Donde la línea de color azul son los valores reales y la naranja el resultado de la red.

Elaboración propia





3.2.2.2 Redes Python para el U270

Al igual que en la tabla 25, la número 26 enlista las 3 redes que se entrenaron para el modelo U270 utilizando Python y Keras, dichas redes presentaron una exactitud de 98, 99 y 99%. Siendo las redes con salidas separadas la que tuvieron un mejor comportamiento.

No.	Capas	Neuronas	Función de activación	Algoritmo de aprendizaje	Salidas	Exactitud
1	1	22	Sigmoid	Gradiente por descenso	Todas (T1, D1, T2, D2 y FDS)	98%
2	1	22	Sigmoid	Gradiente por descenso	T1 y D1	99%
3	1	22	Sigmoid	Gradiente por descenso	T2, D2 y FDS	99%

Tabla 26 . Redes en Python U270
Elaboración propia




Figura 129. Performance Net 22n GD U270

En esta figura se observa el número de épocas y como el error disminuye aumentando la exactitud, alcanzando su máximo desde las primeras épocas, manteniéndose casi de manera lineal desde la época 4 aproximadamente.
Elaboración propia



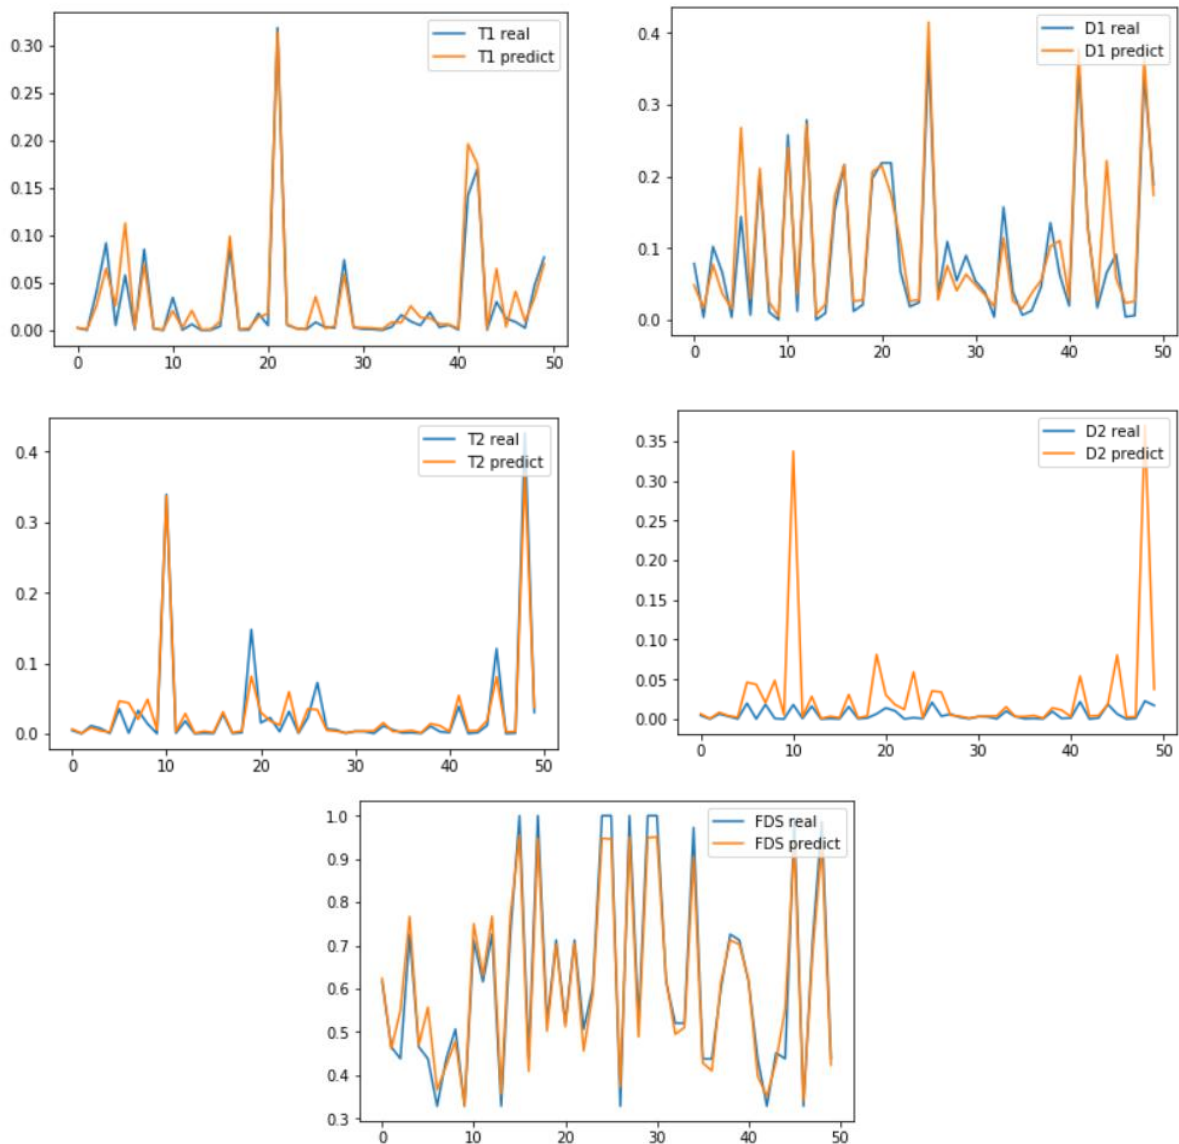


Figura 130. Red 22n GD Python U270

En la tabla se tienen las salidas generadas por la red con una sola capa oculta de 22 neuronas, con una función de activación sigmoide y el algoritmo de gradiente por descenso. Donde la línea de color azul son los valores reales y la naranja el resultado de la red.

Elaboración propia



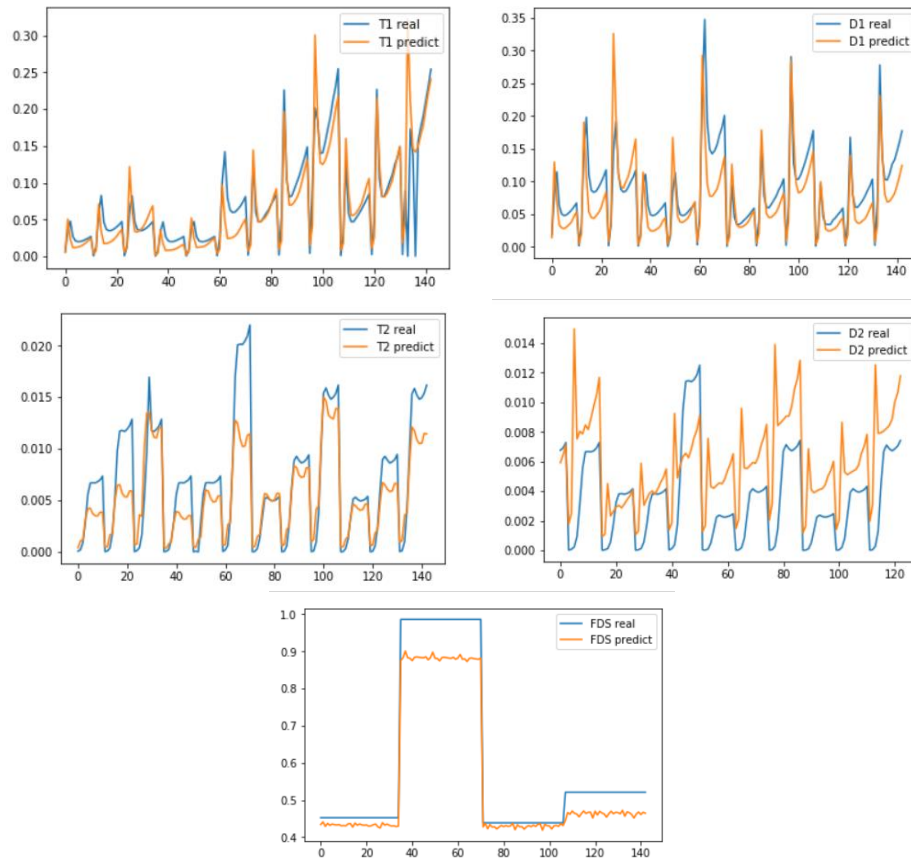


Figura 131. Simulación red 22n GD U270

Se muestran las salidas generadas de la red anterior, al igual que en la red del U170 se utilizaron 140 datos diferentes a los del entrenamiento. Donde la línea de color azul son los valores reales y la naranja el resultado de la red.
Elaboración propia




Figura 132. Performance de Redes 22n GD Python salidas separadas U270

En esta tabla se muestra el performance de dos redes, cada una con una capa oculta de 22 neuronas, con una función de activación sigmoide y el algoritmo de gradiente por descenso. Se tiene como la exactitud aumenta en cada época de entrenamiento, la gráfica del lado izquierdo tiene la salida T1 y D1, mientras que en la de la derecha se tienen T2, D2 y FDS.
Elaboración propia



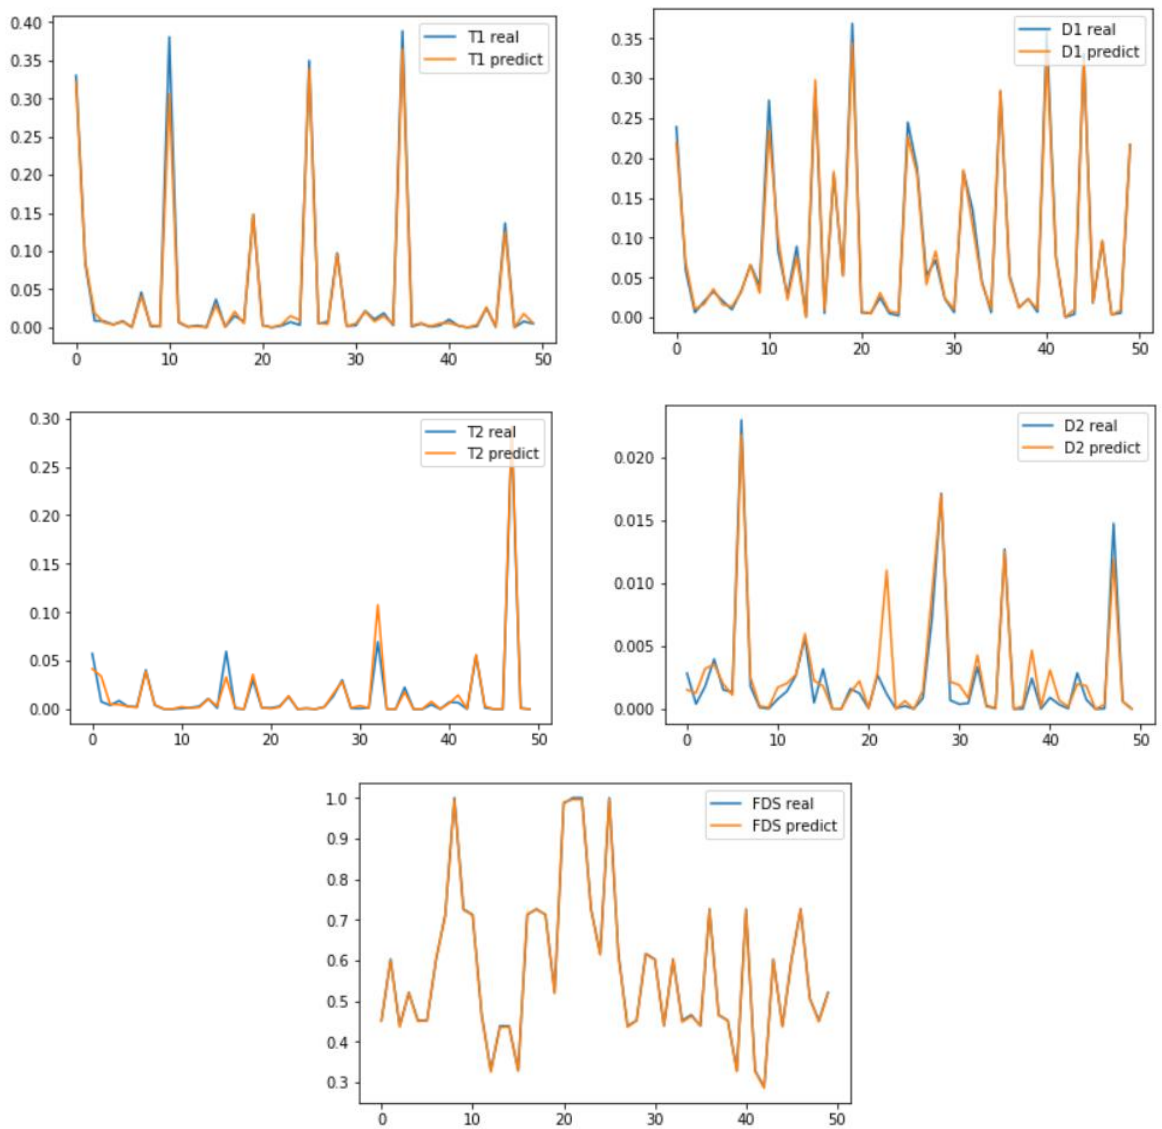


Figura 133. Red 22n GD Python salidas separadas U270

En la tabla se tienen las salidas generadas por las dos redes con una sola capa oculta de 22 neuronas, con una función de activación sigmoide y el algoritmo de gradiente por descenso. Donde la línea de color azul son los valores reales y la naranja el resultado de la red.

Elaboración propia



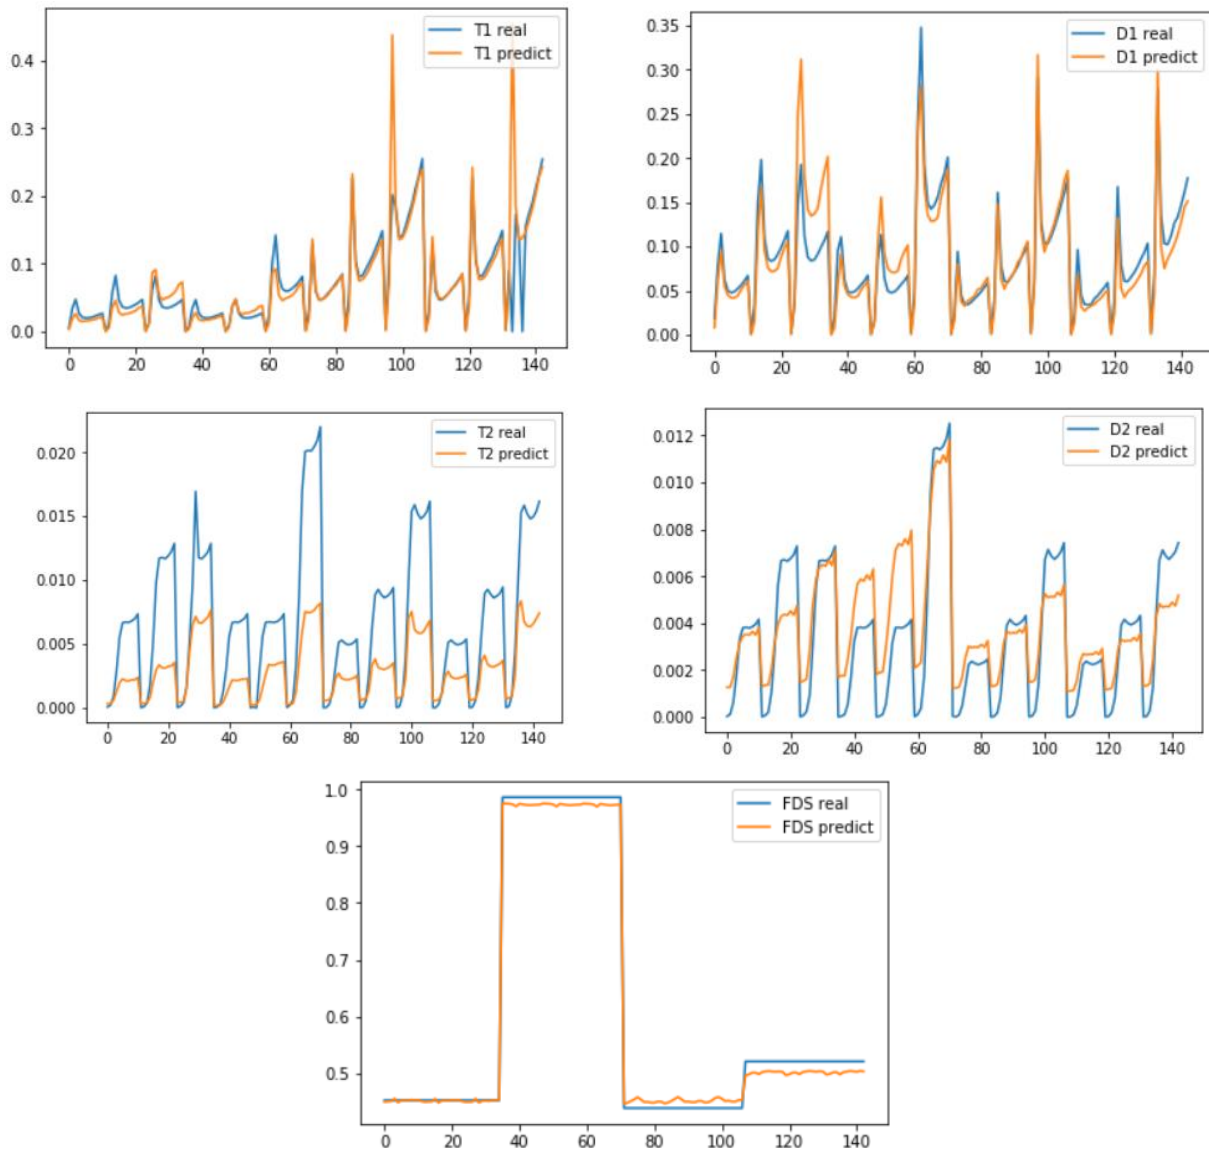


Figura 134. Simulación Red 22n GD Python salidas separadas U270

Se muestran las salidas generadas por las redes que se entrenaron con 2 y 3 salidas, usando 140 datos diferentes a los del entrenamiento. Donde la línea de color azul son los valores reales y la naranja el resultado de la red.

Elaboración propia





3.2.3 Interfaz en Matlab para uso de la RN

Se diseñó una interfaz para que puedan hacer uso de las redes neuronales de una manera simple sin la necesidad de programar en el ambiente de Matlab. En esta sección se muestra la interfaz (fig. 96) la cual está conformada por el título del proyecto y el nombre de la Universidad, así mismo cuenta con 16 campos de texto de los cuales 11 pertenecen a entradas y los 6 restantes a las salidas, cada uno de ellos tiene su etiqueta que indica con que información se debe llenar el campo, por ultimo cuenta con un único botón de Calcular, al hacer clic en este, se manda a llamar a la red neuronal, se toman los datos de los campos de entrada y son entregados a la red para que regrese la salida que corresponde al patrón dado.

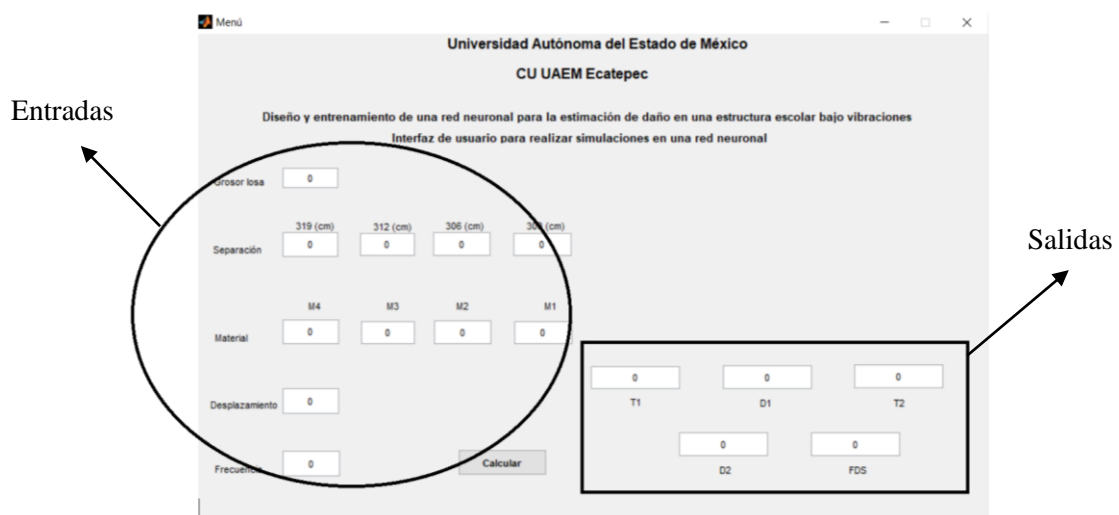


Figura 135. Interfaz de usuario
Elaboración propia

Como se observa en la figura 35, en la parte izquierda se tienen las entradas de la red, y en el derecho las 5 salidas. Para que la interfaz pueda ser usada de manera óptima, se debe de desarrollar la documentación necesaria básico, como lo es un manual de usuario, que contenga los rangos datos aceptados como entradas, para que el resultado sea correcto.

Es importante mencionar que se han dado valores iniciales en los campos, para que no ocurran errores en el programa, si es que el usuario presiona el botón de calcular y los campos están vacíos.





Conclusiones

Se diseñó un modelo en 3D del esqueleto de las estructuras escolares U170 y U270 utilizando el Software SolidWorks, para ambos modelos, se realizó una simulación de dos tipos de análisis: estático y dinámico. Con los análisis antes mencionadas se crearon dos bases de datos, una para cada modelo (se registraron 4224 y 3072 datos respectivamente) realizando configuraciones en los parámetros del software como lo son la frecuencia de la vibración, el desplazamiento en la base, el material del modelo entre otros. Los datos extraídos de las simulaciones fueron dos tensiones y dos desplazamientos, debido a que se realizaron dos simulaciones de vibración: el primero simuló un sismo oscilatorio y el segundo uno trepidatorio además de obtener el factor de seguridad en el análisis estático, dichas fuerzas fueron tomadas de un punto medio de las estructuras.

Los resultados permitieron encontrar que las estructuras se ven mayor afectadas con frecuencias de 1.5 a 3 Hz ya que es cuando se tienen tensiones más altas. Cuando la frecuencia pasa de los 3 Hz la tensión y desplazamientos comienzan a descender, dando la sensación de que la estructura se estabiliza bajo las vibraciones. Cuando se utilizó una frecuencia de 0.5 a 6 Hz, con un desplazamiento en la base de 2 a 110 mm. el límite elástico de la estructura no se sobrepasó, es decir, que la estructura no se fracturaría bajo los esfuerzos a los que fue sometido.

Las simulaciones también permitieron conocer las áreas más vulnerables, éstas se encuentran en los claros transversales de 8 m, ya que en él se centra más la tensión, aun así, se llegaron a tener *FDS* que se podrían considerar como altos 7.3 en el edificio U270 y 9.7 para el U170, esto varía con el material que se utiliza en las vigas, e indica que dichas estructuras podrían soportar hasta 7.3 y 9.7 veces el peso que actualmente están cargando antes de colapsar, el *FDS* brinda conocimiento de qué tan bien fue diseñado el modelo.

Con los datos que se generaron de las simulaciones, se llevó a cabo el entrenamiento de un conjunto de redes neuronales artificiales **utilizando** Matlab como software principal, se realizaron entrenamientos con configuraciones diferentes como el número de capas y neuronas, también





usando diferentes funciones de activación con la finalidad de encontrar la arquitectura que diera los mejores resultados. Se entrenaron las mismas estructuras de NN con los datos de ambos modelos (U170 y U270), la mejor red para el U170 fue la Br 22-10n que es una red de dos capas ocultas, con 22 y 10 neuronas respectivamente, con un algoritmo para reducir el error de Regresión Bayesiana, obteniendo un $MSE = 1.05E-04$ y un $R = 0.9988$; para el U270 el mejor modelo de red fue la Br 44, una red con una sola capa oculta con 44 neuronas, con Regresión Bayesiana, con un $MSE = 5.86E - 05$ y un $R = 0.9995$.

A pesar de que éstos fueron los mejores modelos, se identificó que en las salidas 3 y 4 ($T2$ y $D2$) generaban resultados que más se alejaban de los valores reales debido a esto, se realizaron entrenamientos de redes en donde se separaron las salidas, una red para $T1$ y $D1$ y otra con $T2$, $D2$ y FDS con la finalidad de mejorar los resultados, el experimento fue positivo, se descubrió que al separar las salidas, las redes podían aproximar de mejor manera a $T2$ y $D2$ con un $MSE = 7.82E - 07$ con un $R = 1$ para el U170 y un $MSE = 1.95E - 05$ con un $R = 0.999$ para el U270.

Aunque el separar las salidas, no es la mejor opción ya que una de las ventajas más poderosas de las Redes Neuronales Artificiales es que pueden tener n número de entradas con m número de salidas, es posible que se puedan tener mejores resultados sin la necesidad de separar las salidas con un conjunto de datos más grande.

Se realizaron pruebas de entrenamiento de RNAs utilizando el lenguaje de programación de Python con la librería Keras y los datos de las simulaciones para hacer una comparación del comportamiento de las redes de Matlab con las de Python. Una de las ventajas que brinda Keras es que durante el entrenamiento indica la exactitud que se tiene en cada época se entrenó una red con una sola capa de 22 neuronas usando el Gradiente por descenso para disminuir el error entre las salidas y la función de activación sigmoide. Se obtuvo una exactitud del 98% tanto en el U170 y el U270, sin embargo, se encontró que al igual que en Matlab las salidas del $T2$ y $D2$ no se estaban aprendiendo correctamente así que también se realizaron entrenamientos de redes, separando las salidas, después de hacer esto, la exactitud del entrenamiento fue del 99% para el U270 y del 100%





para el U170. El entrenamiento en el edificio U170 se puede deber a que se cuenta con un mayor número de datos, ya que la diferencia es mayor a 1000 de datos que en el U270. Con base en estos resultados, se puede decir que el entrenamiento de RN en Matlab y Python obtienen resultados muy similares ya que ambos presentaron la misma dificultad para aprender las salidas $T2$ y $D2$ y una exactitud aproximada.

Por último, se hizo el diseño de una interfaz de usuario como propuesta utilizando Matlab, con la cual es posible alimentar y simular la red neuronal de manera sencilla y sin la necesidad de código, se podrían usar nuevos datos, ya sean provenientes de simulación o de características reales de una estructura escolar y obtener un resultado aproximado de la tensión y desplazamiento que sufriría con el movimiento sísmico especificado.





Trabajo futuro

Para optimizar o mejorar los resultados que brindan las redes neuronales para las estructuras U170 y U270 es necesario realizar nuevas simulaciones, utilizando nuevos materiales, agregando un rango mayor de frecuencias y desplazamientos en la base. Como se mencionó anteriormente el tiempo de la simulación y extracción de datos requiere de aproximadamente 25 minutos y el número de simulaciones ideal es de 600 como mínimo.

El paso siguiente en el uso de la inteligencia artificial para evaluar el comportamiento de las estructuras escolares es tener nuevos datos, que pertenezcan a los demás tipos de edificios, para poder realizar el entrenaamiento de una red que aprenda las características de cada uno de ellos, la base de datos tendría que contener los datos suficientes para obtener el mejor aprendizaje en la red.

Una vez lista la red con el conocimiento de todas las estructuras escolares, se tendría que evaluar los edificios de las escuelas, para conocer cuáles son más afectadas por los movimientos sísmicos y si son estructuras seguras para las personas que asisten en ellas.





Referencias

- [1] SEGOB & CENAPRED, (2017) “Sismo”. [En línea]. Disponible en: <http://www.cenapred.gob.mx/es/Publicaciones/archivos/221-CARTELSISMOS.PDF>.
Último acceso: 4 Noviembre 2017
- [2] SSN, (2017). “Sismología de México” [En línea]. *Servicio Geológico Mexicano*, UNAM. Disponible en: <https://www.sgm.gob.mx/Web/MuseoVirtual/Riesgos-geologicos/Sismologia-de-Mexico.html>.
Último acceso: 20 Noviembre 2017
- [3] F. Ventura, (2017). “A 60 años del sismo del Ángel del 28 de julio de 1957 ”. [En línea]. Disponible en: https://www.ern.com.mx/boletines/ERNterate_Notas_Sismo28julio1957.pdf
Último acceso: 21 Noviembre 2017
- [4] J. De la Fuente, (2017). “20 años después: los simos de 1985”. [En línea]. UNAM. Disponible en: http://centro.paot.org.mx/documentos/unam/20_anos_despues_digital.pdf
Último acceso: 21 Noviembre 2017
- [5] SSN, (2017) “Reporte de sismo: Sismo del día 07 de Septiembre de 2017, Chiapas (M 8.2)”. [En línea]. *Servicio Geológico Mexicano*, UNAM. Disponible en: http://www.ssn.unam.mx/sismicidad/reportes-especiales/2017/SSNMX_Chiapas_M84.pdf
Último acceso: 22 Noviembre 2017
- [6] La Jornada, (2017). “Sismo de 8.4 grados, más intenso que el del 85; Chiapas las mayores afectaciones”. *La Jornada*. [En línea]. Disponible en: <http://www.jornada.unam.mx/2017/09/08/sociedad/039n1soc>.
Último acceso: 17 Octubre 2017
- [7] SSN, (2017). “Reporte de sismo: Sismo del día 19 de Septiembre de 2017, Puebla-Morelos(M7.1)”. *Servicio Sismológico Nacional*, UNAM. [En línea]. Disponible en: http://www.ssn.unam.mx/sismicidad/reportesespeciales/2017/SSNMX_rep_esp_20170919_Puebla-Morelos_m71.pdf
Último acceso: 21 Noviembre 2017
- [8] L. Flores, (2017). “Sismo causa 117 muertos en CDMX”. *La jornada*. [En línea]. Disponible en: <http://www.jornada.uanam.mx/2017/029/20/politica/003n1pol>
Último acceso: 17 Octubre 2017





- [9] SSN, (2017). “El servicio sismológico nacional no opera ninguna alerta sísmica”. [En línea] *Servicio Sismológico Nacional, UNAM*. Disponible en: <http://www.ssn.unam.mx/avisos/alerta-simica/>
Último acceso: 17 Octubre 2017.
- [10] SSN, (2017). “¿En cuánto tiempo el SSN reporta la información de un sismo?”. [En línea] *Servicio Sismológico Nacional, UNAM*. Disponible en: <http://www.ssn.unam.mx/avisos/mecanica-de-reportes/>
Último acceso: 17 Octubre 2017.
- [11] SSN, (2017). “Red sismológica nacional”. [En línea] *Servicio Sismológico Nacional, UNAM*. Disponible en: <http://www.ssn.unam.mx/acerca-de/estaciones/>
Último acceso: 17 Octubre 2017.
- [12] L. B. Ugarte Lucuy, M. E. Ruiz Sandoval & B. Spencer. “Estudio de sistemas de control semiactivo en edificios acoplados”. *Concreto y Cemento. Investigación y desarrollo*, vol. 4, n° 1, pp. 18-39, 2012.
- [13] Á. E. Rodríguez Suesca. “Modelación estructural para cargas sísmicas” *Facultad de ingeniería*, vol. 16, n° 23, pp. 25-38, 2007.
- [14] C. Nicolas Mendoza. “Análisis y diseño estructural en acero, de una nave industrial con las especificaciones A.I.S.C. método L.R.F.D. 1993” *Tesis para obtener el título de Ingeniero Civil, Instituto Politecnico Nacional, México*, 16 Noviembre 2007.
- [15] USGS, (2008). “Earthquake Hazards Program: Earthquake Facts And Statistics”. [En línea]. *U.S. Geological Survet*. Disponible en: <http://Neic.Usgs.Gov/Neils/Eqlists/Eqstats.html>
Último acceso: 2008
- [16] H. Coral, J. Ramírez, E. Rosero, P. Thomson, D. Gómez & J. Marulanda. “Diseño, construcción y control de un simulador sísmico unicial tele-operable para modelos estructurales a pequeña escala”. *Ingeniería y Competitividad*, vol. 12, n° 2, pp. 95-115, 2010.
- [17] N. Ogawa, K. Ohtani, T. Katayama & H. Shibata. “Construction of a three-dimensional, large-scale shaking table and development of core technology” *Philosophical Transactions of The Royal Society of London Series A-Mathematical Physical and Engineering Sciences* , n° 359, pp. 1725-1751, 2001.





- [18] SEP, (2017). “Catálogo de estructuras escolares SEP”. [En línea]. Secretaria de Educación Pública, México. Disponible en: <http://www.espacioseducativos.gob.mx/wp-content/uploads/sites/10/2017/10/48.-INIFED.-Catalogo-de-estructuras..pdf>
Último acceso: 15 Diciembre 2017
- [19] SolidWorks, (2017). “Funciones de CAD en 3D ” [En línea]. *Dassault Systèmes*. Disponible en: <https://www.solidworks.es/sw/products/3d-cad/capabilities.htm>
Último acceso: 26 Septiembre 2017
- [20] D. Patrick, (1988). “Neural agents spy traffic errors”.
- [21] Y. Liang, Y. Zhang, A. Sivasubramaniam, M. Jette & R. Shahoo. “BlueGene/L Failure analysis and prediction models” de *Proceedings of international conference on dependable Systems and networks (DSN)*, 2006.
- [22] R. Hilera & V. J. Martínez. “Redes Neuronales Artificiales, Fundamentos, modelos y aplicaciones”. *Alfaomega*, 2000.
- [23] I. Viñuela y I. M. Galván León. “Redes Neuronales Artificiales; un enfoque práctico”. *Madrid: Pearson Prentice Hall*, 2004.
- [24] J. Flores, (2017). “¿Que características debe tener una casa sismo resistente?”. [En línea]. *Revista Muy interesante*. Disponible en: <http://www.muyinteresante.es/curiosidades/preguntas-respuestas/que-caracteristicas-debe-tener-una-casa-sismorresistente-401431441398>
Último acceso: 26 Septiembre 2017.
- [25] F. Peña Mondragón. “Estrategias para el modelado y análisis Sísmico de estructuras históricas”. *Revista de Ingeniería Sísmica*, n° 83, pp. 43-63, julio-diciembre 2010.
- [26] Á. E. Rodríguez Suesca. “Modelación estructural para cargas sísmicas” *Facultad de ingeniería*, vol. 16, n° 23, pp. 25-38, 2007.
- [27] E. Maldonado Rondón, I. D. Gómez Arujo & G. Chio Cho. “Estimación de daño sísmico en edificaciones de mampostería a partir de la aplicación de funciones de vulnerabilidad simuladas” *Revista Ingenierías Universidad Medellín*, vol. 7, n° 13, pp. 39-56, 2008.
- [28] C. J. Marte Jiménez. “Calibración de umbrales de daño sísmico para el análisis de fragilidad sísmica de estructuras de hormigón armado mediante análisis estático no lineal (“Push-Over”)”. *Universidad Politecnica de Cataluña, Tesis de maestría, Barcelona*, Febrero 2014





- [29] C. Gómez y J. Lizarado. “Influencia de la no linealidad de material en las deflexiones inmediatas de vigas de concreto reforzado” *Ingeniería e Investigación*, vol. 27, n° 2, pp. 92-99, 2007.
- [30] L. Saucedo, L. Mata, J. Tirado & J. Ocampo. “Análisis numérico experimental de un rin de aleación AlSi7Mg”. *Científica*, vol. 9, pp. 179-185, 2005.
- [31] A. Herrera, A. Ramos & J. García. “Redes neuronales artificiales para representar la atenuación de la intensidad sísmica”. *Ingeniería y Universidad*, vol. 17, n° 2, pp. 277-292, 2013.
- [32] Gerdau & Dlaco, (2018). “Perfiles estructurales laminados VIGAS W”. [En línea]. Disponible en: <https://www.gerdau.com.co/Portals/4/CatalogoVigas.pdf>
Último acceso: 10 Marzo 2018.
- [33] SolidWorks, (2011). “Introducción a las aplicaciones de análisis” 2011. [En línea]. *Dassault Systemes*. Available: http://www.solidworks.com/sw/docs/simulation_student_wb_2011_esp.pdf.
Último acceso: 20 Marzo 2018.
- [34] H. Gavin P. “The Levenberg-Marquardt algorithm for nonlinear least squares curve-fitting problems” *Department of Civil and Environmental Engineering*, 10 Enero 2019.
- [35] Matlab, (2019). “trainlm”. [En línea]. *MathWorks*. Disponible en: https://la.mathworks.com/help/deeplearning/ref/trainlm.html?s_tid=doc_ta
Último acceso: 4 Julio 2019
- [36] F. Burder y D. Winkler. “Bayesian Regularization of neural networks,” *Methods in Molecular Biology*, n° 458, pp. 25-44, 2008.
- [37] Matlab, (2019). “trainbr” . [En línea]. *MathWorks*. Disponible en: <https://la.mathworks.com/help/deeplearning/ref/trainbr.html;jsessionid=dde54b653776515045ca89fea465>
Último acceso: 4 Julio 2019
- [38] SolidWorks, (2010). “Criterio de máxima tensión de von Mises” [En línea]. *Dassault Systemes*. Disponible en: http://help.solidworks.com/2010/spanish/solidworks/cworks/legacyhelp/simulation/checking_stresses/prot_vonm.html
Último acceso: 27 noviembre 2018.





- [39] SolidWorks, (2013). “Comprobación del Factor de seguridad”. [En línea]. *Dassault Systemes*, 2013. Disponible en: http://help.solidworks.com/2013/spanish/SolidWorks/cworks/c_Factor_of_Safety_Check.html.
Último acceso: 27 Noviembre 2018.
- [40] D. Sakar, R. Bali & T. Sharma. “Practical Machine Learning with Python” *Apress*, 2018.
- [41] Matlab, (2018) “Correlación lineal”. [En línea]. *MathWorks*, Disponible en: https://la.mathworks.com/help/matlab/data_analysis/linear-correlation.html.
Último acceso: 10 Julio 2019

