

UNIVERSIDAD AUTONOMA DE ZACATECAS

Unidad Académica de Ingeniería Eléctrica



**Redes Neuronales Artificiales de regresión generalizada
en espectrometría y dosimetría de neutrones**

Ing. Arturo Reyes Alfaro

Tesis de Maestría

Presentada en la Unidad Académica de Ingeniería Eléctrica de acuerdo a los
requerimientos de la universidad para obtener el título de:

Maestro en Ingeniería y Tecnología Aplicada

Directores de tesis:

Dr. José Manuel Ortiz Rodríguez
Dr. Ma. del Rosario Martínez Blanco
Dr. Luis Octavio Solís Sánchez
Dr. René Héctor Vega Carrillo

RESUMEN

Estamos constantemente expuesto a la radiación, ya sea de manera natural o artificial, la cual existe en un amplio espectro electromagnético, como pueden ser radiación alfa, beta, gamma y la causada por el neutrón, el cual por alto poder de penetración y carencia de carga eléctrica, ser detenido es muy complicado y su medición es una tarea muy compleja. Ya que no se pueden medir de manera directa, se usan sistemas indirectos, utilizando sistemas moderadores para bajar la energía del neutrón, el más usado es el sistema espectrométrico de esferas Bonner (SEEB), que consiste en un detector en el centro de un sistema de un grupo de esferas de polietileno de diámetro diferente, comenzando desde el detector al desnudo. Al haber esferas de diámetro diferente, los neutrones pierden energía según el diámetro de la esfera, de tal forma que cada esfera es eficiente en cierto grupo de energía, y el grupo de respuestas de las esferas se le conoce como matriz de respuesta. Al incidir los neutrones sobre las esferas provoca partículas secundarias, se considera que por cada partícula secundaria detectada es un neutrón detectado. Pero el espectro de neutrones no se da de manera directa de estas mediciones, sino que debe pasar por un proceso de reconstrucción, el cual se logra, resolviendo la ecuación de primer tipo de Fredholm, considerada una ecuación mal condicionada, debido a que el número de incógnitas es mayor que el número de ecuaciones de entrada, se considera que es un sistema mal condicionado. Una vez obtenida las tasas de conteo y la matriz de respuesta, para resolver el espectro de neutrones no es fácil, se usan distintos métodos, usar la inteligencia artificial específicamente redes neuronales artificiales ha sido un tema de interés en los últimos años. En trabajos anteriores, se utilizó las redes neuronales artificiales de propagación hacia adelante, con algoritmo de propagación inversa, para reconstruir el espectro de neutrones y el cálculo de las dosis, y aunque dio buenos resultados, aún existen muchas variables que el usuario puede controlar y otras que no, afectando el desempeño de la red. En este trabajo se utiliza las redes neuronales artificiales de regresión generalizada, como una nueva herramienta para reconstruir el espectro de neutrones y el cálculo de las dos, utilizando 251 espectros compilados de la Organización Internacional de Energía Atómica, de los cuales, el 80 % para entrenar y 20 % para la etapa de prueba. Una de la finalidad de este trabajo, es validar el funcionamiento de la red, utilizando como datos de entrada, las tasas de conteo de tres laboratorios, dos en Alemania

y uno en EUA, y reduciendo estas tasas de conteo, a dos datos de entrada, y a un solo dato. Conforme se reducían el número de entradas, se entrenó en mayor cantidad las redes, con la finalidad de elegir entre más resultados el mejor. Los resultados finales, demostraron el buen funcionamiento de la red utilizando la totalidad de las tasas de conteo de los tres laboratorios, casi de igual manera, reduciendo el número de entradas a dos, mostró muy buenos resultados en el cálculo de las dosis, y buenos resultados en la reconstrucción del espectro, mientras que al reducir el número de entradas a un único dato, utilizando la tasa de conteo del a esfera de cinco pulgadas, y la de ocho, para el cálculo de las dosis, aun mantuvo buenos resultados, mientras que para el espectro de neutrones, no resultaron favorables.

DEDICATORIAS:

A mi familia y amigos.

AGRADECIMIENTOS

Agradezco a mi familia. A mi padre por el apoyo incondicional bajo cualquier situación, por mostrarme los mejores caminos a elegir para así tener la mejor oportunidad de una formación personal, Por enseñarme lo que es la responsabilidad y darme los ánimos para ser siempre mejor y progresar como persona y ahora como profesional. A mi madre por el cariño y darme los ánimos para superar los peores momentos, y para superarme aun en los mejores también, por el cariño y la paciencia de acompañarme en mi crecimiento en todos los aspectos posibles. A mis hermanas, por el apoyo incondicional, por ser siempre personas que nunca dejarán de estar donde se les necesita. A toda mi familia en general, por ser la gente en quien siempre podré confiar, a pesar de cualquier situación, contar con ellos siempre y cada momento de mi vida.

Un agradecimiento al Dr. José Manuel Ortiz Rodríguez, al Dr. Héctor Rene Vega Carrillo, al Dr. Rodrigo Castañeda Miranda y al Dr. Luis Octavio Solís, por la invitación a formar parte del posgrado, y a los proyectos que se encuentran dentro del posgrado, el cual ha sido muy enriquecedor y fue el empujón para dar las bases para una vida profesional.

Contenido

RESUMEN.....	v
Lista de figuras.....	x
Lista de tablas.....	0
CAPITULO 1.....	1
INTRODUCCION.....	1
1.1 Identificación del problema.....	5
1.2 Meta científica.....	6
1.3 Objetivos.....	7
1.3.1 Objetivo general.....	7
1.3.2 Objetivos específicos.....	7
CAPITULO 2.....	9
REVISION DE LITERATURA.....	9
2.1 Inteligencia artificial y redes neuronales.....	9
2.1.1 Redes Neuronales Biológicas.....	10
2.1.2 Redes Neuronales Artificiales.....	12
2.1.2.1 Beneficios de las redes neuronales.....	13
2.1.3 Modelo de una neurona.....	15
2.1.3.1 Función de transferencia.....	18
2.1.4 Modelo de una red neuronal.....	19
2.1.4.1 Red neuronal artificial recurrente.....	21
2.1.4.2 Red neuronal Artificial Mono capa.....	22
2.1.4.3 Red Neuronal multicapa.....	23
2.1.5 Entrenamiento de una RNA.....	25
2.1.6. Redes neuronales artificiales probabilísticas y de regresión generalizada.....	26
2.1.6.1 Redes neuronales probabilísticas.....	26

2.1.6.2. Estructura de una red probabilística.....	26
2.1.6.3. Redes neuronales de regresión generalizada.....	28
2.2.0. Aplicaciones de las RNA.....	29
2.2.1. Problemas inversos.....	30
2.3. Espectrometría de neutrones.....	32
2.4. Dosimetría de neutrones.....	37
CAPITULO 3.....	39
MATERIALES Y METODOS.....	39
3.1. Redes neuronales de regresión generalizada.....	39
3.2. Etapa de entrenamiento.....	40
4. Resultados.....	48
4.1. Resultados con matriz 3He de PTB con 15, 2 y 1 esfera Bonner.....	48
4.1.1. Resultados de 3He de PTB con matriz completa de entrada.....	49
4.1.2. Resultados de 3He de PTB con dos esferas como dato de entrada.....	52
4.1.3. Resultados de 3He de PTB con la esfera de cinco pulgadas como dato de entrada.	54
4.1.4. Resultados de 3He de PTB con la esfera de ocho pulgadas como dato de entrada..	57
4.2. Resultados con matriz con detector de 3He del LANL con 11, 2 y 1 esfera Bonner.....	59
4.2.1. Resultados de 3He de LANL con matriz completa de entrada.....	61
4.2.2. Resultados de 3He de LANL con dos esferas como dato de entrada.....	64
4.2.3. Resultados de 3He de LANL con esfera de cinco pulgadas como dato de entrada.	67
4.2.4. Resultados de 3He de LANL con esfera de ocho pulgadas como dato de entrada..	69
4.3. Resultados con matriz Lil de GSF con 10, 2 y 1 esfera Bonner.....	72
4.1.1. Resultados de Lil de GSF con matriz completa de entrada.....	73
4.1.1. Resultados de Lil de GSF con dos esferas como dato de entrada.....	76
4.1.1. Resultados de Lil de GSF con la esfera de cinco pulgadas como dato de entrada..	78
4.1.1. Resultados de Lil de GSF con la esfera de ocho pulgadas como dato de entrada...	81
CAPITULO 4.....	84

Conclusiones.....	84
Apéndices.....	85
A Anexo I: Expo-ciencias latinoamericana ESI-AMLAT.....	86
B Anexo II: INDOORGANIC INTERNATIONAL.....	91
B.1. INTRODUCCION.....	92
B.1.1. Objetivos.....	93
B.1.1.1. Objetivo general.....	93
B.1.1.2. Objetivos específicos.....	93
B.2. ANTECEDENTES.....	94
B.2.1. Emprendimiento.....	94
B.2.1.1. Errores de un emprendedor.....	95
B.2.1.2. Éxito de un emprendedor.....	95
B.2.2. Etapas de la creación de una nueva empresa.....	96
B.2.2.1. La fase de gestación.....	97
B.2.2.2. Nacimiento de la empresa.....	98
B.2.2.3. La fase posnatal.....	98
B.2.2.4. La fase de desarrollo.....	99
B.2.2.4.1. Desarrollo empresarial.....	99
B.2.2.4.2. Desarrollo Tecnológico.....	100
B.2.2.4.3. Desarrollo comercial.....	100
B.2.2.5. La fase de consolidación.....	101
B.2.2.5.1. Misión, Visión y Valores.....	101
B.2.2.5.2. Análisis interno.....	101
B.2.2.5.3. Análisis externo.....	102
B.2.2.5.4. Planificación estratégica.....	102
B.2.3. Áreas de oportunidad para STARTUPS mexicanas.....	102
B.2.4. Sector alimenticio.....	103

B.3. Metodología.....	104
B.3.1. Creación de una empresa verde.....	105
B.3.1.1. Imagen corporativa.....	105
B.3.1.2. Misión, visión y valores de una empresa.....	106
B.3.1.3. Modelo de gestión de tecnología.....	107
B.3.2. Prototipado.....	108
B.3.2.1. Design thinking.....	109
B.3.2.2. Modelo canvas.....	113
B.4. Resultados.....	114
B.4.1. Diseñando desde sus inicios a INDOORGANIC INTERNATIONAL.....	114
B.4.1.1. Imagen corporativa.....	115
B.4.1.2. Misión, visión y valores de Indoorganic international.....	120
B.4.1.3. Modelo de gestión de tecnología.....	120
B.4.2. Prototipado.....	140
B.4.2.1. Canvas de EVA.....	145
B.4.2.1.1. Segmento de clientes.....	146
B.4.2.1.2. Propuesta de valor.....	146
B.4.2.1.3. Canales.....	147
B.4.2.1.4. Relación con los clientes.....	147
B.4.2.1.5. Flujo de ingresos.....	147
B.4.2.1.6. Recursos clave.....	148
B.4.2.1.7. Actividades clave.....	148
B.4.2.1.8. Socios clave.....	148
B.4.2.1.9. Estructura de costes.....	148
B.4.3. Reconocimientos y otros.....	149
B.4.3.1. Reniecyt.....	149
B.4.3.2. Premios o reconocimientos.....	150

B.4.3.3. Notas periodísticas.....	153
B.4. Conclusiones.....	156
Referencias.....	157

Lista de figuras

Figura 2. 1 Representación en diagrama de bloques del sistema nervioso.....	15
Figura 2. 2 Modelo de una neurona biológica.....	16
Figura 2. 3 Sinapsis entre dos neuronas.....	17
Figura 2. 4. Representación de la analogía de una neurona biológica a una artificial.....	20
Figura 2. 5. Modelo de la neurona McCulloch-Pitts.....	20
Figura 2. 6 Modelo de una neurona artificial.....	21
Figura 2. 7 Función de activación sigmoideal para diferentes valores del parámetro a	23
Figura 2. 8 Red neuronal recurrente elman.....	27
Figura 2. 9 Red neuronal de una sola capa.....	28
Figura 2. 10 Esquema general de una RNA de tres capas.....	29
Figura 2. 11. Red neuronal artificial con dos capas ocultas en notación abreviada.....	30
Figura 2. 12 Estructura de una red neuronal probabilística.....	32
Figura 2. 13 Estructura general de una red neuronal de regresión generalizada.....	34
Figura 2. 14. Modelo de un problema directo.....	35
Figura 2. 15 Modelo de un problema inverso.....	36
Figura 2. 16 Interacción de la radiación con la materia.....	37
Figura 2. 17 Matriz de respuesta del SEEB.....	41
Y	
Figura 3. 1 Pantalla de inicio de la herramienta para entrenar las RNARG.....	48
Figura 3. 2. Segunda pantalla de la herramienta para entrenar RNARG.....	49
Figura 3. 3 Tercera pantalla, donde pide los datos para nombrar la red, la generación de los datos de entrenamiento y prueba, y sobre guardar y graficar la información resultante.....	49
Figura 3. 4 Pantalla de la herramienta, donde se ingresan las rutas de los archivos.....	52
Figura 3. 5 Pantalla de la herramienta donde se ingresa nombre de la red, y donde se pide la generación de las matrices y de guardar y graficar la información final.....	53
Figura 3. 6 Pantalla de la herramienta, durante el entrenamiento de la red.....	53
Figura 3. 7 Pantalla de la herramienta, donde la red ya fue entrenada y entrega los resultados como desempeño, correlación y chi cuadrada.....	53
Figura 4. 1 El mejor espectro reconstruido utilizando las 15 tasas de conteo del sistema de PTB.....	58
Figura 4. 2 El peor espectro reconstruido utilizando las 15 tasas de conteo del sistema de PTB.....	58

Figura 4. 3 El mejor caso para calcular las dosis utilizando las 15 tasas de conteo del sistema de PTB.	59
Figura 4. 4 El mejor caso para calcular las dosis utilizando las 15 tasas de conteo del sistema de PTB.	59
Figura 4. 5 El mejor espectro reconstruido utilizando dos tasas de conteo del sistema de PTB.....	60
Figura 4. 6 El pro espectro reconstruido utilizando dos tasas de conteo del sistema de PTB.....	61
Figura 4. 7 El mejor caso para calcular las dosis utilizando dos tasas de conteo del sistema de PTB	61
Figura 4. 8. El peor caso para calcular las dosis utilizando dos tasas de conteo del sistema de PTB.	62
Figura 4. 9 El mejor espectro reconstruido utilizando la tasa de conteo de la esfera de cinco pulgadas del sistema de PTB.....	63
Figura 4. 10 El peor espectro reconstruido utilizando la tasa de conteo de la esfera de cinco pulgadas del sistema de PTB.....	63
Figura 4. 11. El mejor caso para calcular las dosis utilizando la tasa de conteo proveniente de la esfera de cinco pulgadas del SEEB de la matriz de PTB.....	64
Figura 4. 12 El peor caso para calcular las dosis utilizando la tasa de conteo proveniente de la esfera de cinco pulgadas del SEEB de la matriz de PTB.....	64
Figura 4. 13 . El mejor espectro reconstruido utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema de PTB.....	65
Figura 4. 14. El peor espectro reconstruido utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema de PTB.....	66
Figura 4. 15 El mejor caso para calcular las dosis utilizando la tasa de conteo proveniente de la esfera de ocho pulgadas del SEEB de la matriz de PTB.....	66
Figura 4. 16. El peor caso para calcular las dosis utilizando la tasa de conteo proveniente de la esfera de ocho pulgadas del SEEB de la matriz de PTB.....	67
Figura 4. 17 El mejor espectro reconstruido de neutrones, utilizando las 11 tasas de conteo del sistema de LANL.....	70
Figura 4. 18 El peor espectro reconstruido de neutrones, utilizando las 11 tasas de conteo del sistema de LANL.....	70
Figura 4. 19 El mejor caso para calcular las dosis utilizando la tasa de conteo, utilizando las 11 tasas de conteo del SEEB de la matriz de LANL.....	71
Figura 4. 20 El mejor caso para calcular las dosis utilizando la tasa de conteo, utilizando las 11 tasas de conteo del SEEB de la matriz de LANL.....	71
Figura 4. 21. El mejor espectro reconstruido utilizando dos tasas de conteo del sistema de LANL...	72
Figura 4. 22. El peor espectro reconstruido utilizando dos tasas de conteo del sistema de LANL.....	73

Figura 4. 23. El mejor cálculo de las dosis utilizando dos tasas de conteo del sistema de LANL.....	73
Figura 4. 24 El mejor cálculo de las dosis utilizando dos tasas de conteo del sistema de LANL.....	74
Figura 4. 25. El mejor espectro reconstruido utilizando la tasa de conteo de la esfera de cinco pulgadas del sistema del LANL.....	75
Figura 4. 26 El peor espectro reconstruido utilizando la tasa de conteo de la esfera de cinco pulgadas del sistema del LANL.....	75
Figura 4. 27. El mejor cálculo de las dosis utilizando la tasa de conteo de cinco pulgadas del sistema de LANL.....	76
Figura 4. 28 El peor cálculo de las dosis utilizando la tasa de conteo de cinco pulgadas del sistema de LANL.....	76
Figura 4. 29 . El mejor espectro reconstruido utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema del LANL.....	77
Figura 4. 30 El peor espectro reconstruido utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema del LANL.....	78
Figura 4. 31 El mejor cálculo de las dosis utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema de LANL.....	78
Figura 4. 32 El peor cálculo de las dosis utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema de LANL.....	79
Figura 4. 33 El mejor espectro reconstruido utilizando las tasas de conteo del sistema completo de GSF.....	81
Figura 4. 34 El peor espectro reconstruido utilizando las tasas de conteo del sistema completo de GSF.	82
Figura 4. 35 El mejor cálculo de las dosis utilizando las tasas de conteo del sistema completo de GSF.	82
Figura 4. 36 El peor cálculo de las dosis utilizando las tasas de conteo del sistema completo de GSF.	83
Figura 4. 37 El mejor espectro reconstruido utilizando dos tasas de conteo del sistema de GSF.....	84
Figura 4. 38 El peor espectro reconstruido utilizando dos tasas de conteo del sistema de GSF.....	84
Figura 4. 39 El mejor cálculo de las dosis utilizando dos tasas de conteo del sistema completo de GSF.	85
Figura 4. 40 El peor cálculo de las dosis utilizando dos tasas de conteo del sistema completo de GSF.	85
Figura 4. 41 . El mejor espectro reconstruido utilizando la tasa de conteo de la esfera de cinco pulgadas del sistema GSF.....	86
Figura 4. 42 El peor espectro reconstruido utilizando la tasa de conteo de la esfera de cinco pulgadas del sistema GSF.....	87

Figura 4. 43 El mejor cálculo de las dosis utilizando las tasa de conteo de la esfera de cinco pulgadas del SEEB de GSF.....	87
Figura 4. 44 El peor cálculo de las dosis utilizando las tasa de conteo de la esfera de cinco pulgadas del SEEB de GSF.....	88
Figura 4. 45 El mejor espectro reconstruido utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema GSF.....	89
Figura 4. 46 El peor espectro reconstruido utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema GSF.....	89
Figura 4. 44 El mejor cálculo de las dosis utilizando la tasa de conteo de la esfera de ocho pulgadas del SEEB de GSF.....	90
Figura 4. 44 El peor cálculo de las dosis utilizando la tasa de conteo de la esfera de ocho pulgadas del SEEB de GSF.....	90
Figura B. 1. Actividades según el sector de desarrollo.....	100
Figura B. 2. Etapas de la metodología Design Thinking.....	112
Figura B. 3. Modelo canvas.....	114
Figura B. 4.. Imagen corporativa de Indoorganic.....	117
Figura B. 5.. Página Web de Indoorganic.....	118
Figura B. 6. Logotipo con el nombre comercial y el eslogan.....	118
Figura B. 7. Segundo logotipo con el nombre comercial y un segundo eslogan.....	119
Figura B. 8. Logotipo vectorizado.....	119
Figura B. 9. Imagen de Indoorganic.....	119
Figura B. 10. Red social de Indoorganic.....	120
Figura B. 11.. Logotipo y eslogan del primero producto “EVA”.....	120
Figura B. 12.. Página 1 del modelo de gestión de tecnología.....	122
Figura B. 13. Página 2 del modelo de gestión de tecnología.....	123
Figura B. 14. Página 3 del modelo de gestión de tecnología.....	124
Figura B. 15. Página 4 del modelo de gestión de tecnología.....	123
Figura B. 16. Página 5 del modelo de gestión de tecnología.....	123
Figura B. 17.. Página 6 del modelo de gestión de tecnología.....	123
Figura B. 18. Página 7 del modelo de gestión de tecnología.....	123
Figura B. 19. Página 8 del modelo de gestión de tecnología.....	123
Figura B. 20.. Página 9 del modelo de gestión de tecnología.....	123

Figura B. 21. Página 10 del modelo de gestión de tecnología.....	123
Figura B. 22. Página 11 del modelo de gestión de tecnología.....	123
Figura B. 23. Página 12 del modelo de gestión de tecnología	123
Figura B. 24. Página 13 del modelo de gestión de tecnología.....	123
Figura B. 25. Página 14 del modelo de gestión de tecnología	123
Figura B. 26. Página 15 del modelo de gestión de tecnología	123
Figura B. 27. Página 16 del modelo de gestión de tecnología.....	123
Figura B. 28. Página 17 del modelo de gestión de tecnología	123
Figura B. 29. Página 18 del modelo de gestión de tecnología.....	123
Figura B. 30. Página 19 del modelo de gestión de tecnología.....	124
Figura B. 31. Propuesta de un diseño para EVA y como se vería en un entorno.....	142
Figura B. 32. Segundo diseño de Eva, con la variabilidad de un mueble.....	143
Figura B. 33. Propuesta de un diseño para exteriores.....	144
Figura B. 34. Propuesta de diseño para exteriores.....	145
Figura B. 35. Diseño del CASE donde se encontrará la electrónica de EVA.....	146
Figura B. 36. Modelo canvas de EVA.....	147
Figura B. 37. Reniecyt de la empresa INDOORGANIC.....	151
Figura B. 38. Constancia de plática durante la semana nacional del emprendedor en CONACYT..	152
Figura B. 39. Convocatoria la cual ganaron para ser acreedores a unas becas.....	152
Figura B. 40. Presentación como una de las mejores empresas verdes por cleantech.....	153
Figura B. 41. Imagen de la entrega de reconocimientos por el diplomado de modelo de gestión de tecnología.....	153
Figura B. 42. Nota publicada en NTR.....	154
Figura B. 43. Nota publicada en el sol de Zacatecas.....	154
Figura B. 44. Nota publicada en Enfoque noticias.....	155
Figura B. 45. Nota publicada en Proyecto puente.....	155
Figura B. 46. Nota publicada en digitalpost.....	156
Figura B. 47. Nota publicada en Ciencia y salud.....	156
Figura B. 48. Nota publicada en unotv.....	157

Lista de tablas

Tabla 1 Funciones de transferencia.....	27
Tabla 2 Clasificación de los neutrones según su energía.....	41
Tabla 3 Esferas que constan el SEEB de tres laboratorios.....	52
Tabla 4 Resultados de entrenamientos con el SEEB, con un detector de He, de PTB, para la reconstrucción del espectro.....	56

Tabla 5 Resultados de entrenamientos con el SEEB, con un detector de He, de PTB para el cálculo de las dosis.....	56
Tabla 6. Resultados de entrenamientos de las redes para la reconstrucción del espectro de neutrones con el SEEB, con un detector de HE, del LANL.....	68
Tabla 7. Resultados de entrenamientos de las redes para el cálculo de las dosis con el SEEB, con un detector de HE, del LANL.....	68
Tabla 8 Resultados de entrenamientos con el SEEB, con un detector de Lil, de GSF.....	80
Tabla 9. Resultados de entrenamientos con el SEEB, con un detector de Lil, de GSF.....	80

CAPITULO 1

INTRODUCCION

El término de Inteligencia Artificial (IA), fue formulado en 1950 por Alan Turing, pero fue hasta 1956 que el término fue acuñado por John McCarthy, en la conferencia de Dartmouth, donde McCarthy, Marvin Minsky, Nathaniel Rochester y Claude E. Shannon establecieron las bases de la IA, como una rama dentro de la Informática. Desde entonces, tanto el hardware como el software han

mejorado considerablemente, aunque a pesar de los avances, la tecnología de la IA está lejos de estar completa [CITATION Rus95 \l 2058][CITATION AAn11 \l 2058].

La IA intenta asimilar procesos que el cerebro humano es capaz de hacer de manera natural, como la capacidad de aprendizaje[CITATION Fri08 \l 2058][CITATION Lug98 \l 2058], y aunque para nosotros son tareas relativamente sencillas, crear tecnologías con estas capacidades es muy complicado. Existen dos vertientes en la IA, el primero que estudia el ámbito psicológico y fisiológico de la naturaleza del aprendizaje, y el segundo estudia el ámbito tecnológico, buscando sistemas informáticos cada vez más complejos [CITATION Hau97 \l 2058][CITATION YuW09 \l 2058].

El termino IA, en un término general indica la capacidad que tiene un artefacto para realizar los mismos tipos de funciones que caracterizan la forma de procesar del cerebro humano. Desarrollar un artefacto con estas características es lo que ha despertado el interés en el estudio de la IA a pesar de la constante evolución de la tecnología, el que un sistema informático tenga la capacidad de simular el aprendizaje humano es aún un objetivo lejos de lograr [CITATION Neg05 \l 2058].

Para que se le pueda considerar sistema de IA, debe cumplir con tres componentes: representación, razonamiento y aprendizaje. El sistema de IA debe ser capaz de almacenar conocimiento, aplicar el conocimiento almacenado para la solución de un problema y adquirir nuevo conocimiento por medio de la experiencia [CITATION Ras \l 2058]. La finalidad de la IA es la mejora de las capacidades de la computación dándoles cierta inteligencia. La arquitectura del cerebro humano ha sido un punto de estudio extenso, intentando emularla. Las Redes Neuronales Artificiales (RNA) representan un área de la IA, la cual básicamente es un intento de simular el cerebro humano. El estudio de las RNA también es llamada ingeniería neuronal o computacional neuronal [CITATION Sri05 \l 2058].

La aplicación de las RNA es bastante versátil, ya que se puede aplicar a diferentes áreas como el procesamiento de información, reconocimiento de rostros, planeación y predicción, y en los últimos años, en el área de ciencias nucleares, concretamente en la espectrometría de neutrones [CITATION Feh99 \l 2058].

La espectrometría de radiación térmica, puede ser usada para describir la medición de la intensidad de un campo, con respecto a la energía, la frecuencia o cantidad de movimiento. La distribución de la intensidad con uno de estos parámetros se refiere con el término “espectro”, es decir, la medición de energía de los espectros de neutrones, es la variación de la intensidad de esta radiación con la energía. Además del espectro de energía se considera una segunda cantidad, que es la variación de la intensidad de esas radiaciones con función del ángulo de incidencia sobre un cuerpo, dentro de un campo de radiación, que se refiere como “dosis” [CITATION Tho04 \l 2058][CITATION Lac04 \l 2058].

En el área de protección radiológica, la espectrometría de neutrones es un tema delicado, a causa de la ausencia de carga eléctrica, por lo que determinar el espectro de neutrones y la medición de la dosis es una tarea compleja. Al no tener carga eléctrica, su alto poder de penetración y el hecho que no causa ionización directa, se vuelve en un tema delicado y de gran importancia, al encontrar los campos de neutrones bajo diferentes ambientes, ya sea dentro de institutos como laboratorios, centros de investigación, etc. O de manera natural como lo son los rayos cósmicos, y es por eso el interés por determinar la dosis equivalente [CITATION Tho04 \l 2058].

La espectrometría de neutrones está presente en el área de medicina, protección radiológica e investigación, por lo cual es importante conocer a detalle la investigación relacionada con los parámetros de la interacción con la materia y los neutrones, además de sus efectos. La radiación provocada por neutrones, tiene una transferencia de energía lineal, y es considerado como una radiación peligrosa [CITATION Veg15 \l 2058]

Para una correcta evaluación de la dosis efectiva recibida por los trabajadores en diferentes instalaciones nucleares, se requieren dosímetros personales o de área, calibrados con fuentes de neutrones cuyos espectros son similares. Sin embargo se encuentran muchos problemas al intentar determinar el espectro de energía de neutrones. La dosimetría de radiación de neutrones es uno de las tareas más complejas en el área de protección radiológica. La detección de neutrones se realiza por medio de reacciones nucleares, las cuales resultan de partículas energéticas cargadas como protones, alfas, etc. El conocimiento de estos espectros de neutrones se puede obtener a través de técnicas espectrométricas [CITATION Sha01 \l 2058], aunque existen distintos dispositivos, la mayoría son agrupables en detectores de tiempo de vuelo, de métodos de reacciones nucleares, métodos de retroceso nuclear, principalmente dispersión y los integrales [CITATION Tho04 \l 2058], y el más usado, el sistema espectrométrico de esferas Bonner (SEEB), el cual consta de un grupo de esferas de diámetro diferente de polietileno y un sensor de neutrones térmicos en el centro. El SEEB tiene las ventajas de tener un amplio rango de energías (desde neutrones térmicos hasta neutrones en GeV), y la gran variedad de sensores térmicos que permiten adaptar la sensibilidad del lugar de trabajo de manera específica. [CITATION Tho02 \l 2058] [CITATION Har99 \l 2058] (Ortiz Rodriguez J. M., Reyes Alfaro, otros, 2014).

Por otro lado, algunas de las desventajas del SEEB es que son demasiado pesadas, tienen una baja resolución de la energía, necesitan una matriz de respuesta, además de la complejidad de los métodos de reconstrucción y el largo periodo de irradiación que requieren las esferas. [CITATION Bar14 \l 2058].

El problema es que el espectro de neutrones no se da de manera directa de las mediciones del SEEB, está dado por una serie de tasas de conteo, que va junto a la matriz de respuesta para determinar el espectro, a través de un procedimiento de reconstrucción [CITATION Mar09 \l 2058]. Para reconstruir

el espectro de neutrones, existen varios métodos, como Monte Carlo [CITATION Lin95 \l 2058], regularización [CITATION Rou80 \l 2058], parametrización y métodos iterativos [CITATION ICR01 \l 2058].

Recientemente, se ha incursionado en nuevas tecnologías con el fin de reconstruir el espectro de neutrones, como lo son el método de máxima entropía [CITATION Reg02 \l 2058], algoritmos genéticos [CITATION Muk02 \l 2058] y redes neuronales artificiales (RNA). Las RNA son una rama de la Inteligencia Artificial (IA), son una estructura de caja negra no lineal, que puede ser usado con los métodos de estimación de parámetros convencionales. La tecnología de RNA es reconocida como una herramienta de modelado poderosa, una RNA, es un procesador distribuido en paralelo, que a través de procesos de aprendizaje, adquiere conocimiento o experiencia. Una RNA simula una estructura computacional altamente paralela, con muchos elementos de procesamiento individuales, o neuronas. Las neuronas aprenden a través de procesos iterativos que ajustan sus pesos sinápticos, además de un conjunto de reglas para la solución del problema de aprendizaje, el algoritmo de entrenamiento. [CITATION Veg15 \l 2058].

El método basado en RNA, es aplicado para reconstruir el espectro de neutrones, utilizando las funciones de respuesta independientes provenientes del SEEB. La aplicación de esta tecnología, en el campo de protección radiológica, aún no está completa, existen algunos problemas y necesidades que requieren investigación.

En trabajos previos, se incursiono en aplicar redes neuronales artificiales de propagación inversa (RNAPI), aplicada en el problema de reconstrucción del espectro de neutrones. A razón que esta arquitectura de red tiene muchos parámetros que el usuario puede controlar y otros que no, y no existe una fórmula que asegura obtener la arquitectura optima con los parámetros exactos. Se ha hecho la propuesta de seguir incursionando en la tecnología de RNA. La red neuronal de regresión generalizada

(RNARG) tiene características que pueden asegurar que la red funcione de manera óptima con pocos parámetros que modificar, algunas de las características de esta red son: su poder de generalización, solo requiere un parámetro que es la constante de propagación, la capacidad para converger con el mínimo global en una sola iteración, etc. [CITATION Ort15 \l 2058]

El objetivo de este trabajo es obtener las RNARG, que puedan resolver el problema de la reconstrucción del espectro de neutrones, además del cálculo de la dosis y los instrumentos.

1.1 Identificación del problema

Debido a que el número de detectores es menor que el número de grupos de energía en el que se despliega el espectro, se considera a la ecuación de Fredholm, una ecuación mal condicionada. Esto se interpreta que no existe una única solución, sino un número infinito de soluciones, y encontrar una con significado físico no es una tarea trivial. Las matemáticas convencionales ya no son suficientes para poder resolver esta ecuación, por lo que se ha optado por la tecnología de IA como nueva herramienta para resolver el problema, específicamente las RNA [CITATION Veg061 \l 1034].

En el campo de protección radiológica, específicamente en la espectrometría de neutrones, las RNA han sido una herramienta novedosa. Una de las características más importantes de las RNA es su capacidad de adaptación, de aprender de su entorno y mejorar su desempeño a través de un aprendizaje. El aprendizaje se logra durante los procesos iterativos, ajustados en sus pesos sinápticos, ya que las conexiones entre las neuronas, determinan la función de la red. Idealmente, la red obtiene la experiencia a través del aprendizaje.

El poder de una RNA se encuentra en la arquitectura, habiendo incursionado en encontrar la arquitectura ideal en trabajos anteriores. Se trabajó con las redes neuronales de propagación inversa, donde existe el problema que no hay una fórmula para conocer los parámetros adecuados para el

correcto funcionamiento de la red, y existen muchos parámetros que el usuario puede controlar y otros que no. En este trabajo se propone otro tipo de RNA, siendo la de regresión generalizada, la cual, algunas de sus ventajas son: solo tiene un parámetros la red, su poder de generalización, y que solo requiere una iteración para su aprendizaje.

Debido a la complejidad de resolver la ecuación de Fredholm, el uso de métodos como la IA, es un camino que falta mucho por incursionar. Algunas de las ramas de la IA que se ha estado trabajando, como son los algoritmos genéticos y las RNA, las cuales han mostrado un futuro prometedor para estos nuevos métodos. Y las RNA de regresión generalizada muestran tener las capacidades necesarias, con los beneficios de esta arquitectura.

1.2 Meta científica

Obtener las arquitecturas de redes neuronales artificiales de regresión generalizada, capaz de reconstruir el espectro de neutrones, y el cálculo de la dosis equivalente. Aprovechando las características de este tipo de red, la cual es usada para la función de aproximación, la red proporciona estimaciones de las variables continuas y de convergencia, siendo una red con un rápido aprendizaje, el cual no requiere proceso iterativo, lo que se traduce como el poder minimizar el tiempo empleado para obtener las redes neuronales, asegurando resultados satisfactorios.

Se maneja desde el pre-procesamiento de información, el cual servirá para la etapa de entrenamiento y prueba de las redes neuronales, con el fin de obtener redes neuronales artificiales, para reconstruir el espectro, el cálculo simultáneo de la dosis, de los instrumentos, y la combinación entre estos, utilizando la tasa de conteo de dos detectores de neutrones térmicos, siendo el ^6Li (Eu) y ^2He ,

utilizando uno, dos y siete datos de las tasas de conteo. Para finalizar, obtener los pesos sinápticos de las arquitecturas finales.

1.3 Objetivos

1.3.1 Objetivo general

Obtener arquitecturas de redes neuronales artificiales de regresión generalizada, capaces de resolver el problema de la reconstrucción del espectro de neutrones, además el cálculo simultaneo del a dosis equivalente y de los instrumentos.

1.3.2 Objetivos específicos

- Pre-procesamiento de la información compilada del compendio de la Agencia Internacional de Energía Atómica (AIEA).
- Entrenar las redes neuronales artificiales, utilizando uno, dos y siete datos de entrada, utilizando las tasas de conteo de la matriz PTB, para reconstruir el espectro, calcular las dosis, y los instrumentos, y la combinación entre estos.
- Entrenar las redes neuronales artificiales, utilizando uno, dos y siete datos de entrada, utilizando las tasas de conteo de la matriz LANL, para reconstruir el espectro, calcular las dosis, y los instrumentos, y la combinación entre estos.
- Entrenar las redes neuronales artificiales, utilizando uno, dos y siete datos de entrada, utilizando las tasas de conteo de la matriz GSV, para reconstruir el espectro, calcular las dosis, y los instrumentos, y la combinación entre estos.
- Obtener los pesos sinápticos de todas las arquitecturas.

CAPITULO 2

REVISION DE LITERATURA

2.1 Inteligencia artificial y redes neuronales

En 1956 se establecieron las bases de la Inteligencia Artificial (IA) por John McCarthy, Marvin Minsky, Nathaniel Rochester y Claude E. Shannon, como un campo independiente dentro de la informática. Y en 1990 se le da la definición de IA como el desarrollar algoritmos que requieran máquinas para realizar tareas cognitivas, la cual los humanos pueden hacer de manera sencilla. Un sistema de IA debe ser capaz de obtener conocimiento, aplicar el conocimiento obtenido para resolver

problemas, y adquirir nuevo conocimiento a través de la experiencia, además que el sistema tiene tres componentes clave: Representación, razonamiento y aprendizaje [CITATION Hay01 \l 2058].

Las RNA son una rama de la IA, las cuales, de manera general, intentan simular el proceso del cerebro humano. La computación basada en esta tecnología, es completamente diferente de la forma de trabajar con la computación convencional. El cerebro es una computadora en paralelo muy complejo y no lineal, tiene la capacidad de organizar la estructura, a través de las unidades conocidas como neuronas, de esta misma manera, la computación neuronal, tiene unas unidades conectadas en paralelo conocidas como neuronas, y es capaz de trabajar más rápido que la computación convencional, como por ejemplo, el procesamiento de información, para reconocer rostros a través de la visión humana, mientras que al cerebro le toma entre 100-200ms, para una computadora, esta tarea es bastante compleja [CITATION Fal12 \l 2058][CITATION Kor12 \l 2058] [CITATION Hay01 \l 2058].

Al nacer, el cerebro tiene una gran estructura y habilidad de construir sus propias reglas, conocidas como “experiencia”. Una neurona en “desarrollo”, es sinónimo de un cerebro plástico: La plasticidad permite que el sistema nervioso se desarrolle para adaptarse a su entorno. Así como la plasticidad parece ser esencial para el funcionamiento de las neuronas como unidades de procesamiento de información en el cerebro humano, las neuronas artificiales lo son para las redes neuronales [CITATION Hay01 \l 2058].

2.1.1 Redes Neuronales Biológicas

El sistema nervioso se puede representar como un sistema de tres etapas, como se muestra en la figura 2.1. El sistema central del sistema, es el cerebro, representado como red neuronal en el diagrama, el cual, continuamente está recibiendo información y tomando decisiones apropiadas. En el diagrama se observa el sentido de la transmisión de información, representado por el sentido de las flechas, siendo

unidireccional o bidireccional. Los receptores convierten estímulos del cuerpo humano o de un ambiente externo en impulsos eléctricos que se transmite a la red neuronal, mientras que los actuadores, convierten los impulso eléctricos generados por la red neuronal en respuestas discernibles para el sistema [CITATION Hay01 \l 2058].

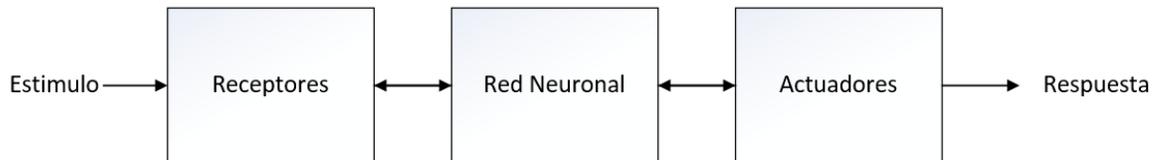


Figura 2. 1 Representación en diagrama de bloques del sistema nervioso.

Ramón y Cajál en 1911, introducen la idea de la neurona, como un elemento individual que constituye al cerebro. A pesar de la tasa relativamente lenta de funcionamiento de una neurona, el cerebro humano compensa el funcionamiento al tener una tasa realmente grande de neuronas interconectadas masivamente entre ellas. Se estima que existen alrededor de 60 trillones de conexiones, dando como resultado, una enorme eficiente estructura [CITATION Hay01 \l 2058].

Todos los procesos del cuerpo humano, se relacionan de alguna manera con la actividad, o inactividad de las neuronas. Básicamente, la neurona está constituida por tres partes, como se muestra en la figura 2.2, las cuales son: dendritas, soma y axón. Cuando la neurona es estimulada o excitada través de las dendritas, y alcanza un umbral, la neurona se activa, pasando la señal por el soma al axón, para transmitir las señales a otras neuronas que están conectadas a través del axón con sus dendritas [CITATION Arb03 \l 2058].

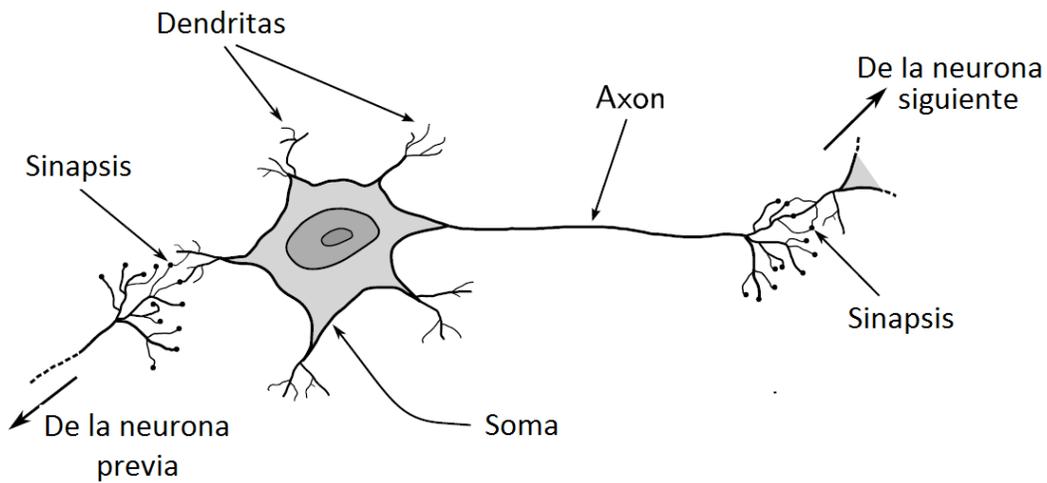


Figura 2. 2 Modelo de una neurona biológica.

En general, una neurona envía su salida a otras por su axón, y este lleva la información por medio de diferencias de potencial eléctrico, como se muestra en la siguiente imagen.

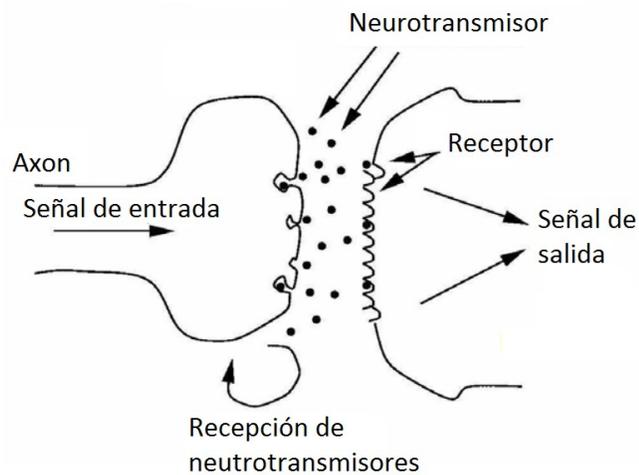


Figura 2. 3 Sinapsis entre dos neuronas

La señal proveniente de las dendritas, es combinada, la señal resultante logra transmitirse solo si es mayor que el umbral. La salida de la neurona es una función no lineal de la entrada, por lo tanto, la membrana funge como un filtro no lineal. Debido a la no linealidad, la estructura en paralelo, las redes neuronales biológicas, tienen una única habilidad de aprendizaje y almacenar conocimiento, además de

la capacidad de generalizar conocimiento a los impulsos aun no vistos en el mundo exterior, se convirtieron en una fuente de inspiración para crear herramientas teóricas y tecnológicas, llamadas redes neuronales artificiales [CITATION Mat08 \l 2058].

2.1.2 Redes Neuronales Artificiales

Las RNA, fueron originalmente una simulación abstracta de los sistemas nerviosos biológicos, constituidos por un conjunto de unidades llamadas neuronas. Las RNA son más que otra forma de emular ciertas características propias de los humanos, como la capacidad de memorizar y de asociar hechos. Si se examinan con atención, aquellos problemas que no pueden expresarse a través de un algoritmo, se observara que todos ellos tienen una característica en común: la experiencia. El primer modelo de red neuronal fue propuesto en 1943 por McCulloch y Pitts, en términos de un modelo computacional de actividad nerviosa. Este modelo era un modelo binario, donde cada neurona tenía un escalón o umbral prefijado, y sirvió de base para los modelos posteriores [CITATION Hay01 \l 2058].

2.1.2.1 Beneficios de las redes neuronales

Las RNA son reconocidas por su estructura altamente paralela, segundo, por su habilidad de aprendizaje y generalización. Por generalización se refiere a la red neuronal que produce salidas razonables, para las entradas que no fueron encontradas durante el entrenamiento. Por estas dos características, las RNA son capaces de resolver una amplia gama de problemas. El uso de redes neuronales ofrece las siguientes propiedades y capacidades útiles [CITATION Hay01 \l 2058]:

- **No-linealidad:** Esta es una propiedad de alta importancia, particularmente si el mecanismo físico responsable de la generación de la señal de entrada, no es lineal.
- **Mapeo de Entrada-Salida:** El proceso de entrenamiento de una red, consiste en una única señal de entrada y su correspondiente respuesta. La red es presentada con un ejemplo elegido al azar del conjunto, y los pesos sinápticos de la red son modificados para minimizar la diferencia entre la respuesta deseada y la real. El entrenamiento es repetido para muchos ejemplos del conjunto total, hasta que no hay más cambios significativos en los pesos sinápticos, así, la red aprende a partir de ejemplos mediante la construcción del mapeo de Entrada-Salida de la inferencia estadística.
- **Adaptabilidad:** Las RNA tienen una capacidad para adaptar sus pesos sinápticos a los cambios en el entorno que los rodea.
- **Auto organización:** Significa generalización, de esta forma una red puede responder a datos o situaciones que no ha experimentado antes, pero que puede inferir sobre la base de su entrenamiento.
- **Respuesta probatoria:** En el contexto de clasificación de patrones, una red neuronal puede diseñarse para proporcionar información no solo acerca de un patrón particular, sino también sobre la confianza en la decisión tomada. Esto sirve para rechazar patrones ambiguos, si se presentan, y de ese modo mejorar el redimiendo.
- **Información contextual:** Cada neurona en la red, es potencialmente afectada por la actividad global de todas las neuronas, ya que el conocimiento está representado por la estructura misma, y el estado de activación del a red.
- **Tolerancia a fallos:** Las RNA pueden reconocer patrones de información con ruido, distorsión o incompletos, pero que además, pueden seguir trabajando. Las RNA pueden seguir funcionando a pesar de esto, ya que almacenan información de forma distribuida y con un alto grado de redundancia.

- **Implementabilidad:** por su naturaleza altamente en paralelo de una RNA, la hace potencialmente rápida para el cálculo de ciertas tareas, provocando que sea adecuada para su aplicación en tecnologías de gran escala.
- **Uniformidad de análisis y de diseño:** como procesadores de información universales, se manifiestan ciertas características como:
 - ❖ Las neuronas representan la unidad común de las RNA.
 - ❖ Esto permite una versificación para compartir teorías y algoritmos en diferentes aplicaciones.
 - ❖ Se pueden diseñar de manera modular.
- **Analogía neurobiológica:** Las RNA están diseñadas a partir de una analogía del cerebro. Donde se une la vista de la neurobiológica, la cual ve a las redes neuronales como una herramienta para la interpretación del fenómeno de la neurobiología, y los ingenieros, que ven a la neurobiología como un grupo de ideas para resolver problemas complejos, donde los métodos convencionales es difícil de resolver.

2.1.3 Modelo de una neurona

Para hacer una transición de la neurona biológica a un modelo de la neurona artificial, primero se debe tener en cuenta la descripción del modelo de una neurona biológica. En la siguiente figura se muestra el proceso de la imitación de la neurona biológica a la artificial.

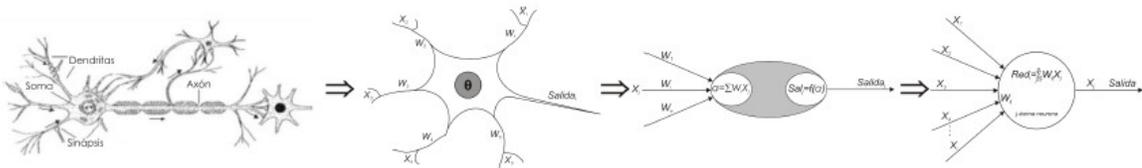


Figura 2. 4. Representación de la analogía de una neurona biológica a una artificial.

El modelo básico de las RNA, se muestra en la figura 2.5, usualmente referida como la neurona McCulloch-Pitts (FAUSETT 1004). La cual contiene esencialmente los mismos componentes que la neurona biológica.

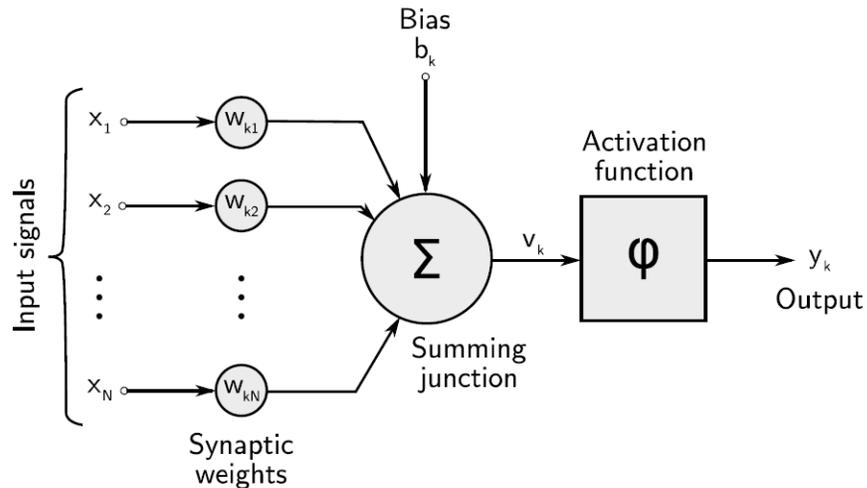


Figura 2.2

Figura 2. 5. Modelo de la neurona McCulloch-Pitts

En la Figura 2.6 se muestra el esquemático de una neurona. La cual recibe las señales de entrada x_i , provenientes de cada j-esima neurona de la capa anterior. Cada conexión a la i-esima neurona tiene asociado un valor, llamado *pesos sináptico*. El valor de las conexiones entre la salida de la j-esima neurona y la entrada de la i-esima neurona se describe por w_{ji} . También se muestra de manera gráfica, el modelo de una neurona artificial. En la figura se observa que el modelo incluye la matriz de pesos, los sumadores, el vector de ganancias, la función de transferencia y el vector de salida. Donde la barra representada por R , es el grupo de entradas, dando una señal P , siendo la señal que se multiplica por los pesos sinápticos W . Además se observa la suma con

el valor sesgo b , dando el valor $b + Wp$, el cual es la señal que entra a la función de transferencia produciendo la salida a .

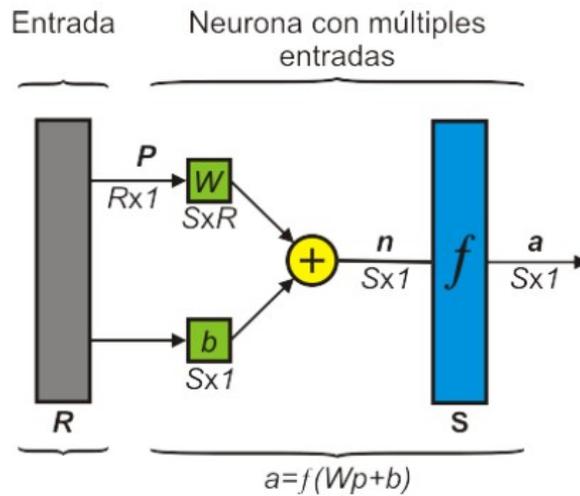


Figura 2. 6 Modelo de una neurona artificial

Las conexiones sinápticas son representadas por el grupo de pesos. El valor por cada peso controla el valor de la señal que se pasa al sumador, de tal forma que el valor de entrada de cada red se calcula con la siguiente ecuación[CITATION Han10 \l 2058] :

$$red_1 = \sum_{j=1}^n x_j W_{ij} \tag{2.1}$$

Se denota por x_i , las señales que provienen de otras neuronas y que son capturadas por las dendritas.

Los pesos W_{ji} son la intensidad de la sinapsis que conecta dos neuronas. Las señales de entrada, se transmiten a través de una ganancia o peso sináptico, que modifica estas señales dentro de cada neurona, ya sea de manera excitatoria o inhibitoria, el nodo de la sumatoria acumula estas señales de entrada, pasando a la salida a través de un umbral, y una vez que se calculó la activación de la neurona, el valor de salida equivale a:

$$X_i = f_i(red_1) \quad (2.2)$$

Donde red_1 o también conocido como a , es la activación de la neurona, f representa la función de activación que corresponde a la encargada de transformar la entrada red_1 en el valor de salida x_i .

Modelos de neuronas simples también pueden incluir una conexión de sesgo que tiene por defecto reducir o aumentar la entrada de la red. Se denota el sesgo como b_k , el peso de esta conexión puede ser positivo o negativo (Matijevic, 2008). La salida final de la red queda como:

$$x_i = f_i(red_i + b_k) \quad (2.3)$$

Hay muchas maneras de definir la función de activación, tales como función de umbral, función sigmoïdal, y la función de tangente hiperbólica. El tipo de función de activación depende del tipo de la red neuronal que se diseña. La variedad de elecciones que se pueden hacer, incluye a una función comúnmente usada, llamada función sigmoïdal [CITATION Han10 \l 2058]

$$f_i(u) = \frac{1}{1 + e^{-au}} \quad (2.4)$$

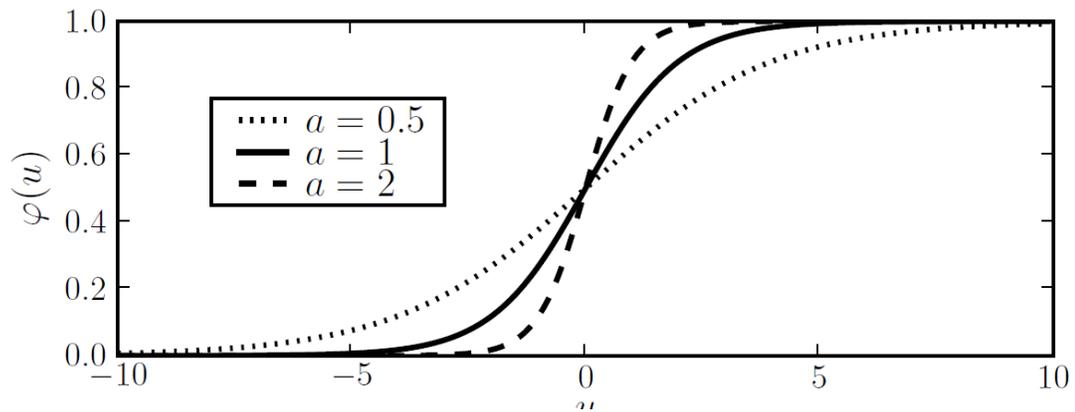


Figura 2. 7 Función de activación sigmoideal para diferentes valores del parámetro a .

2.1.3.1 Función de transferencia

La salida de la neurona se ingresa a una función de transferencia que es la que se encarga en convertir la señal de la neurona en una salida real a través de algún algoritmo. Las funciones son la identidad, generalmente la salida de la función de transferencia, es el resultado del elemento de procesamiento.

Típicamente, se usa la misma función de activación para todas las neuronas en cualquier capa, pero esto no significa que deba ser así. En la mayoría de los casos se usa una función de activación no lineal.

La siguiente tabla hace una relación de las funciones de transferencia más comunes empleadas en las redes neuronales.

Tabla 1 Funciones de transferencia

NOMBRE	RELACION ENTRADA/SALIDA	ICONO	FUNCION
LIMITADOR FUERTE	$a=0 \ n < 0$		HARDLIM

	$a=1 n \geq 0$		
LIMITADOR FUERTE SIMETRICO	$a=-1 n < 0$ $a=+1 n \geq 0$		HARDLIMS
LINEAL POSITIVA	$a=0 n < 0$ $a=n n \geq n$		POSLIN
LINEAL	$a=n$		PURELIN
LINEAL SATURADO	$a=0 n < 0$ $a=n 0 \leq n \leq 1$ $a=1 n > 1$		SATLIN
LINEAL SATURADO SIMETRICO	$a=-1 n < -1$ $a=n -1 \leq n \leq 1$ $a=+n > 1$		SATLINS
SIGMOIDAL LOGARITMICO	$a = \frac{1}{1+e^{-n}}$		LOGSIG
TANGENTE SIGMOIDAL HIPERBOLICA	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$		TANSIG
COMPETITIVA	$a=1$ Neurona con n max $a=0$ El resto de neuronas		COMPET

2.1.4 Modelo de una red neuronal

Aunque una sola neurona puede realizar ciertas funciones de procesamiento de información simples, una única unidad no es capaz de resolver problemas prácticos, es por eso que el poder de las RNA se encuentra en la arquitectura, por lo que se usa una gran cantidad de unidades conectadas (Ortiz Rodriguez & otros, 2011).

Las RNA son un sistema altamente en paralelo, donde todas las neuronas en una capa tendrían las mismas entradas, y cada neurona crearía su propia salida, sin embargo, una capa de neuronas no está limitado en relación de número de entradas y numero de neuronas por capa.

Para describir una RNA multicapa, se debe distinguir entre las matrices de los pesos que están conectadas a las entradas y las matrices conectadas entre capas. Las matrices de los pesos conectadas a las entradas, se denominan como pesos de entrada IW , mientras que las matrices procedentes de las capas de salida se les conocen como pesos de capa EI . (Ortiz Rodriguez & otros, 2011)

Una Red neuronal multicapa es una herramienta muy potente y puede resolver problemas más complicados que los que se logra con redes de una sola capa. La red multicapa consiste en una combinación de neuronas, capas de neuronas y conexiones sinápticas, las son capaces de transmitir las señales a través de las capas. Cada capa tiene su propia matriz de pesos W , un vector de sesgo b , y un vector de salida a . Las capas de la red multicapa juegan diferentes roles. Cuando se muestra una red como arquitectura x-y-z, hace referencia a x como el número de neuronas en la capa de entrada, y el número de neuronas en la capa oculta, y z como el número de neuronas en la capa de salida, teniendo en cuenta que puede haber más capas ocultas (Ortiz Rodriguez & otros, 2011).

Los elementos de una red neuronal se encuentran agrupados en capas, siendo cada capa conformada por un cierto grupo de neuronas, las capas de una red se pueden catalogar como [CITATION Lee04 \l 2058]:

- **Capa de entrada:** Es donde los nodos están los elementos de un vector con características externas. En esta capa no se procesa información.

- **Capas ocultas:** En esta capa se encuentran los elementos que no tienen contacto con el medio exterior, sus elementos pueden tener diferentes conexiones y son las que determinan el funcionamiento de la red.
- **Capa de salida:** En esta capa recibe la información de las capas ocultas y se presenta el resultado al medio exterior.

La manera en que las neuronas de una red están estructuradas, está completamente ligado con el algoritmo de entrenamiento usado para entrenar la red. Se requiere conocer las reglas de los algoritmos de entrenamientos para hacer un correcto diseño de una red neuronal y asegurar una buena estructura. En general, se puede identificar tres tipos de RNA: RNA recurrente, RNA mono capa y RNA multicapa

2.1.4.1 Red neuronal artificial recurrente

Las redes que son completamente conectadas, tienen caminos de retroalimentación entre todos los elementos que las conforman. La complejidad de esta red es mucha mayor comparación a la otra, el intercambio de información es más complejo dependiendo del algoritmo, y pueden propagar información al tiempo, lo que se puede traducir, como predecir eventos. En la siguiente figura, se muestra la arquitectura básica de la red recurrente Elman, es una red de retro propagación de dos capas, con la adición de retroalimentación de la salida de la capa oculta, con la entrada de la red. La retroalimentación le permite a la red generar y detectar patrones variantes en el tiempo [CITATION Hay01 \l 2058].

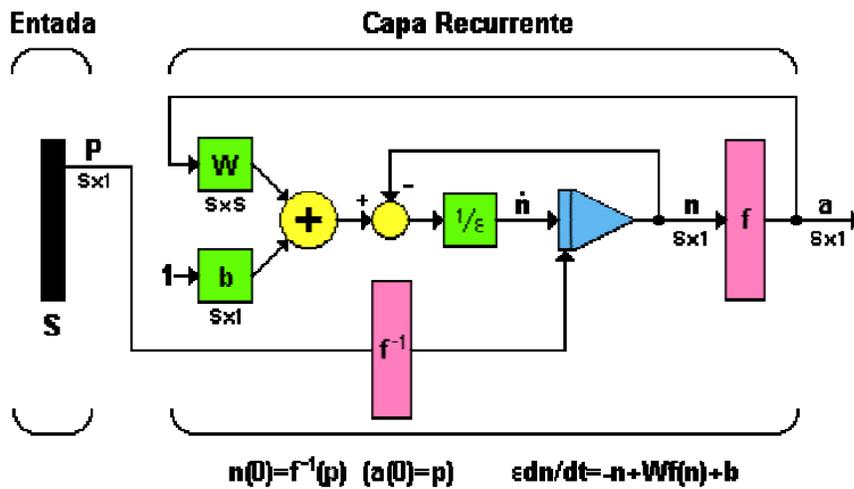


Figura 2. 8 Red neuronal recurrente elman

2.1.4.2 Red neuronal Artificial Mono capa

En una red neuronal en capas, las neuronas son organizadas en forma de capas. En la forma más básica de una red en capas, es cuando se tiene una capa de entrada con los nodos que reciben los estímulos externos, y transmiten la información a las neuronas de la capa de salida, pero no viceversa. En la figura 2.9 se muestra la arquitectura de la red de una sola capa, donde se muestra la capa de entrada y de salida [CITATION Hay01 \l 2058].

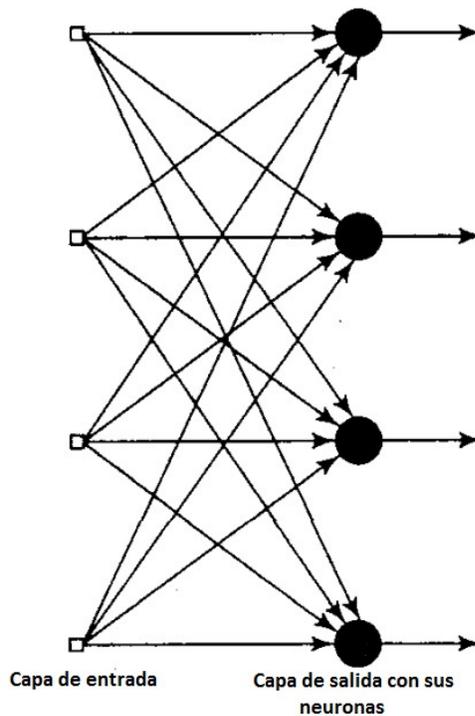


Figura 2. 9 Red neuronal de una sola capa.

2.1.4.3 Red Neuronal multicapa

El segundo tipo de red neuronal es la multicapa, se distingue por tener una o más capas ocultas, las cuales tiene como unidad, las “neuronas ocultas” o “unidades ocultas”. Por lo general, la arquitectura de la red multicapa, consiste en la capa de entrada, con n unidades de entrada, una capa de salida con m unidades de salida, y una o unas capas ocultas, que se encuentran en el intermedio, entre las capas de entrada y salida, el cual consta de unidades intermedias o neuronas. En la figura 2.10 se muestra una arquitectura con una sola capa oculta, siendo una red de tres capas [CITATION Les93 \l 2058].

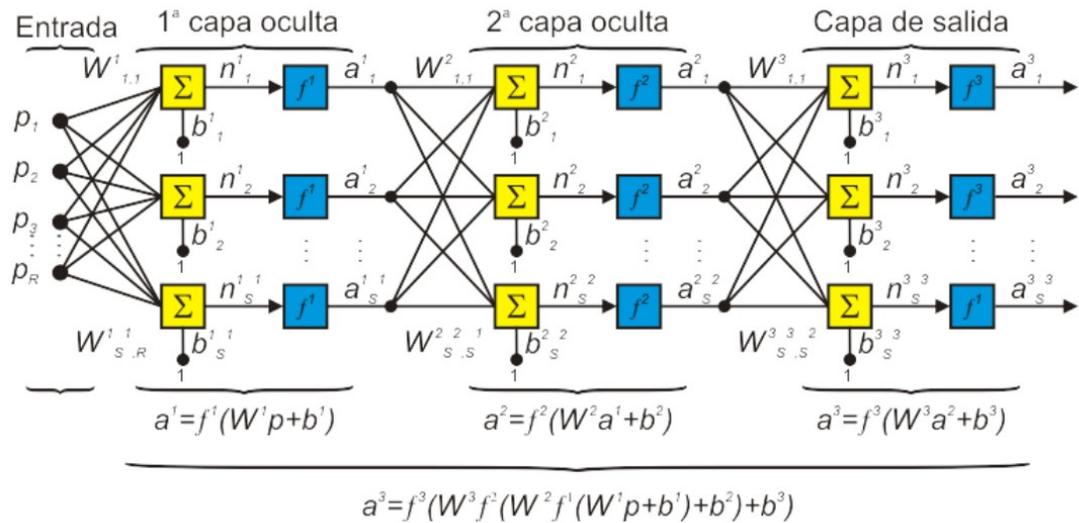


Figura 2. 10 Esquema general de una RNA de tres capas.

Como se observa en la figura 2.10, en una red neuronal, la capa de entrada no es en sí una capa de neuronas, si no, que son los puntos o nodos los que recogen las señales que provienen del exterior. En esta capa no se procesa la información, si no que las capas ocultas recolectan la información de la capa de entrada, y la procesan. El número de capas ocultas, las neuronas que existen en cada capa oculta, y la forma en que se conectan, varían dependiendo el tipo de red, siendo el mayor problema en el diseño de redes neuronales [CITATION Ort13 \l 2058].

En la figura 2.11, muestra nuevamente, una red de tres capas con una notación abreviada. En la figura se puede observar, que la red tiene un vector de entrada R, S neuronas en la primera capa, S2 en la segunda capa, y así sucesivamente conforme al número de capas ocultas. De tal forma, se puede decir una capa, con S1 entradas, s2 neuronas, y una s1*s2 pesos sinápticos w2. La salida de la capa es a1, siendo la entrada de la siguiente capa, y la salida de esta capa siendo a2 [CITATION Ort13 \l 2058].

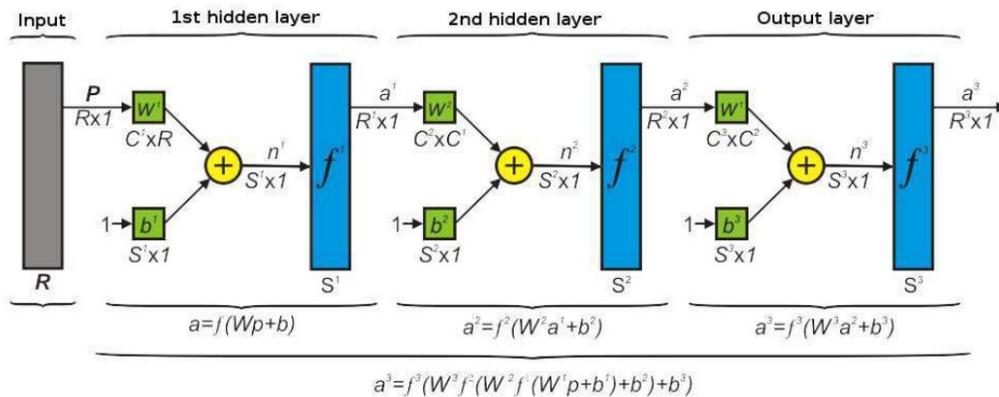


Figura 2. 11. Red neuronal artificial con dos capas ocultas en notación abreviada.

Se distinguen dos tipos de arquitecturas en lo que se categoriza dentro de las redes neuronales de propagación hacia adelante:

- **Arquitectura de propagación hacia adelante:** Este tipo de arquitectura, no tiene conexión hacia atrás, de la salida de una neurona, a la entrada. La red no tiene memoria de valores de salidas previas y el estado de activación de las neuronas.
- **Arquitectura de propagación hacia atrás:** Existen conexiones desde la salida a entradas de las neuronas, y la red puede mantener memoria de los estados previos, y la siguiente etapa depende no solo de las señales de entrada, también de los estados de la red.

2.1.5 Entrenamiento de una RNA

Una de las características destacadas de las RNA, es la propiedad es que la red aprenda de su entorno, y a través de este aprendizaje, obtener nueva experiencia. Una RNA aprende a través de procesos iterativos de ajustes en sus pesos sinápticos y sus umbrales. El grupo de bien establecidas reglas, para la solución del problema del aprendizaje, también es llamado algoritmo de aprendizaje. No existe un

único algoritmo de aprendizaje para el diseño de las redes, existen distintos algoritmos que se acomodan a las arquitecturas de las RNA [CITATION Bra02 \l 2058].

2.1.6. Redes neuronales artificiales probabilísticas y de regresión generalizada

2.1.6.1 Redes neuronales probabilísticas

Las redes neuronales probabilísticas, pueden ser utilizadas para problemas de clasificación de datos. A diferencia del proceso utilizado para problemas de regresión, en el cual se realiza ajustes de pesos y biases, de acuerdo al error presentado, en el proceso de clasificación nos e realiza ningún ajuste de peso, y solo los patrones de salida son determinados mediante la comparación y el cálculo de distancias [CITATION Cad08 \l 2058].

Las redes probabilísticas tienen dos objetivos fundamentales. Primero, estimar a partir de un conjunto de datos disponibles, distribuciones de probabilidad condicionadas y/o estructuras de dependencia, a través de algún método de aprendizaje; y en segundo, generar nuevos conocimientos a través de denominadas técnicas de propagación de la evidencia.

2.1.6.2. Estructura de una red probabilística

Las redes neuronales probabilísticas están compuestas por cuatro capas: una capa de entrada, la cual consiste en d neuronas, donde a es la dimensión de los datos de entrada, una capa de patrones, la cual consiste en N neuronas, una por cada vector ejemplo, una capa sumatoria de k neuronas, donde k es el número de clases y una capa de decisión, la cual consiste en una neurona, se representa la arquitectura en la figura 2.12 [CITATION Gui13 \l 2058].

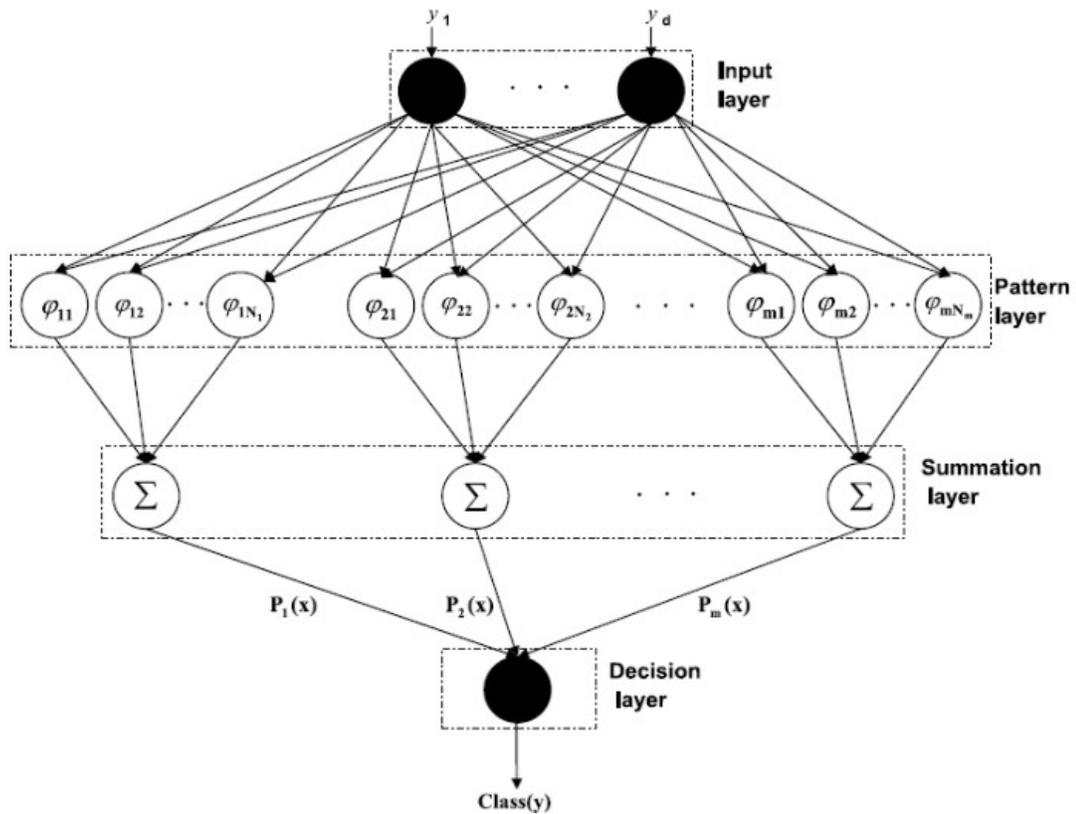


Figura 2. 12 Estructura de una red neuronal probabilística.

Cuando se le presenta a la red un vector de entrada a ser clasificado, la segunda capa se ocupa de calcular las distancias desde el vector de entrada hasta cada uno de los vectores o patrones ejemplo, a través de la función, y se produce un vector cuyos elementos indican como esta de ser la entrada respecto a la entrada entrenada. La función de la siguiente capa, es sumar las contribuciones para cada clase de entrada y producir con ellas, un vector de salida con las probabilidades. Finalmente, una función de trasferencia de salida, selecciona la máxima de estas probabilidades y produce un 1 para esa clase, y cero para las demás. [CITATION Cad08 \l 2058][CITATION Gui13 \l 2058].

Comparando con una red neuronal probabilística, siendo una variación de estas mismas, las redes neuronales de regresión generalizada (RNARG), son más veloces al ser entrenadas [CITATION Ort15 \l 2058]

2.1.6.3. Redes neuronales de regresión generalizada

Las RNARG como las redes probabilísticas, requiere solo una pequeña fracción de entrenamientos. El uso de RNARG es en muchos sentidos ventajoso, debido a su capacidad de converger con el resultado deseado solo con poca información disponible. A diferencia de las RNAPI, que requieren de muchos datos que el usuario debe controlar, estas redes, la información que requieren para hacer un ajuste satisfactorio, es pequeño, además del beneficio de que se puede hacer sin intervención del usuario. El único dato que requieren las RNARG, es el llamado constante de “spread” o de generalización. Otras de las características de las redes de regresión generalizada, además de su rápido entrenamiento, es que solo consta de una capa de salida lineal, después de la primera capa oculta, lo cual, garantiza que la red convergerá con el mínimo global [CITATION Ort15 \l 2058] [CITATION Mar16 \l 2058].

Las RNARG son usadas por la función de aproximación, es una red de propagación hacia adelante, basada en una regresión no lineal. Las aproximaciones de cualquier función entre la entrada y el conjunto de datos de salida, relacionando la estimación de la función directamente de los datos de entrenamiento [CITATION Spe90 \l 2058]

La red consta de cuatro capas como se muestra en la figura 2.13: la capa de entrada, la capa de patrón, la capa de suma y la capa de salida. El número de unidades en la capa de entrada depende del número de parámetros a observar. La capa de entrada, se conecta con la capa de patrón y cada neurona muestra el patrón de formación y su salida. La capa de patrón es conectada a la capa de suma, la cual tiene dos tipos de procesos de suma, las cuales son, la unidad de división y las unidades de suma. La suma y la

capa de salida, normalizan el conjunto de datos de salida. Durante el entrenamiento, la función de base radial y funciones de activación lineal son usadas dentro de la capa oculta y las de salida [CITATION Gup14 \l 2058].

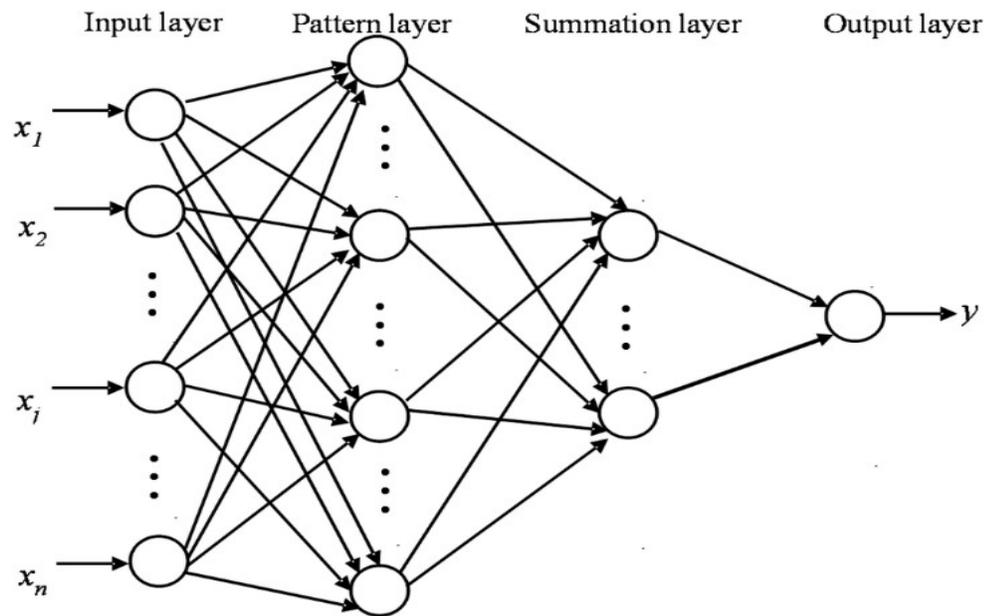


Figura 2. 13 Estructura general de una red neuronal de regresión generalizada

2.2.0. Aplicaciones de las RNA

Aun dentro de las aplicaciones, se pueden categorizar el tipo de aplicación como: de desarrollo, de realización y de comprobación. En otras palabras, las aplicaciones candidatas, son aquellas que en un principio podrían ser resueltas por las RNA. Las aplicaciones en desarrollo son aquellas en las que se han realizado los estudios oportunos del problema y se dispone de un prototipo de red para resolver una versión simplificada del problema. Y las aplicaciones demostradas, son redes que de hecho ya están siendo utilizadas para resolver un problema real.

Las áreas donde las RNA son aplicadas, son bastante variadas, consideradas como sistemas que resuelven eficazmente los problemas de emparejamiento, clasificación y complemento de vectores.

Entre las áreas de aplicación de las redes se encuentra: Análisis financiero; Procesado de imágenes en medicina, industria y defensa; Diagnóstico médico y comercial; Robótica y control; reconocimiento y síntesis de voz; clasificación de datos provenientes de sensores; comprensión de codificación de información y la resolución de problemas inversos.

2.2.1. Problemas inversos

De acuerdo con Hadamard, se dice que una ecuación es planteada directo, si la ecuación tiene una solución y es única, y si la solución es estable con respecto a toda perturbación, mientras que el problema inverso no. Debido a esto, en el problema inverso es necesario poner en forma explícita cualquier información disponible a priori sobre el modelo de parámetros. En la figura 2.11 se muestra un esquema de un problema directo, mientras que en la figura 2.12 se muestra el esquema de un problema inverso [CITATION Gut10 \l 2058][CITATION DaS10 \l 2058].

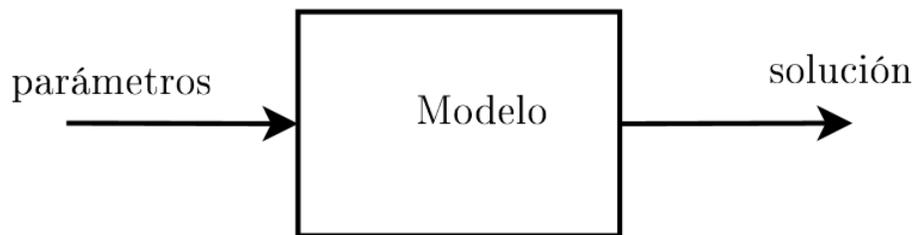


Figura 2. 14. Modelo de un problema directo.

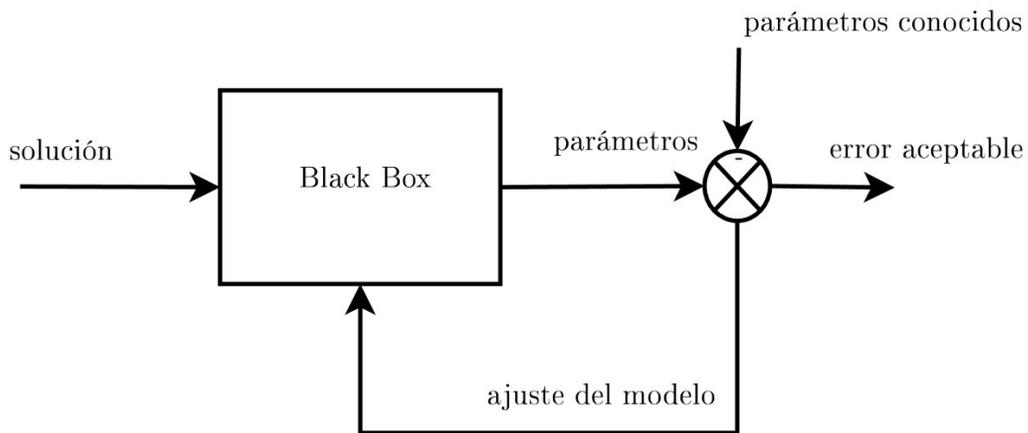


Figura 2. 15 Modelo de un problema inverso.

El problema inverso consiste en obtener una correlación en el cual, a partir de determinar parámetros, se describe de forma analítica el modelo. Enfoques más usuales consisten en utilizarse herramientas numéricas, donde se quiere obtener una caja negra o black box, que represente el modelo inverso adecuadamente. Los problemas inversos son parte importante de muchas disciplinas científicas: Determinación de estructuras cristalinas, tomografía en medicina, prospección acústica y electromagnéticas en geofísica, reconstrucción de sucesos pasados y física de radiación [CITATION Lju99 \l 2058].

Algunos ejemplos de problemas inversos; tomografía axial computarizada, ajuste de un modelo, deconvolucion, mallado o remallado, imágenes radioastronómicas, navegación, análisis de imágenes, geofísica y análisis numérico, el cual consta de la solución de ecuaciones integrales, tales como la ecuación de Fredholm de primera clase como se muestra en la ecuación 2.5 [CITATION DaS10 \l 2058].

$$\int_a^b k(x, s)z(s)ds = y(x) \tag{2.5}$$

En el área de protección radiológica, se encuentra presente los problemas inversos, donde se busca resolver la ecuación integral de Fredholm para reconstruir el espectro de neutrones.

2.3. Espectrometría de neutrones

Dentro de la radiación electromagnética, está la radiación alfa, beta, gamma, rayos X y la producida por los neutrones. Las radiaciones gamma y rayos X, tienen un gran poder de penetración, que depende de la energía asociada a cada tipo de onda, y la producida por los neutrones tiene un mayor poder de penetración, como se observa en la siguiente figura. Donde se observa, que el poder de penetración de los rayos alfa, es muy bajo, siendo detenidos por delgadas hojas de papel; mientras que las partículas beta, que requieren hojas de cobre; un tercer tipo, causa aún menos ionización, pero con mayor poder de penetración que los anteriores, y requiere materiales de varios centímetros de grosor para ser detenidos, siendo los rayos gamma y X; Por último, se encuentra la radiación emitida por el neutrón, el cual es el que tiene mayor poder de penetración[CITATION Bak01 \l 2058].

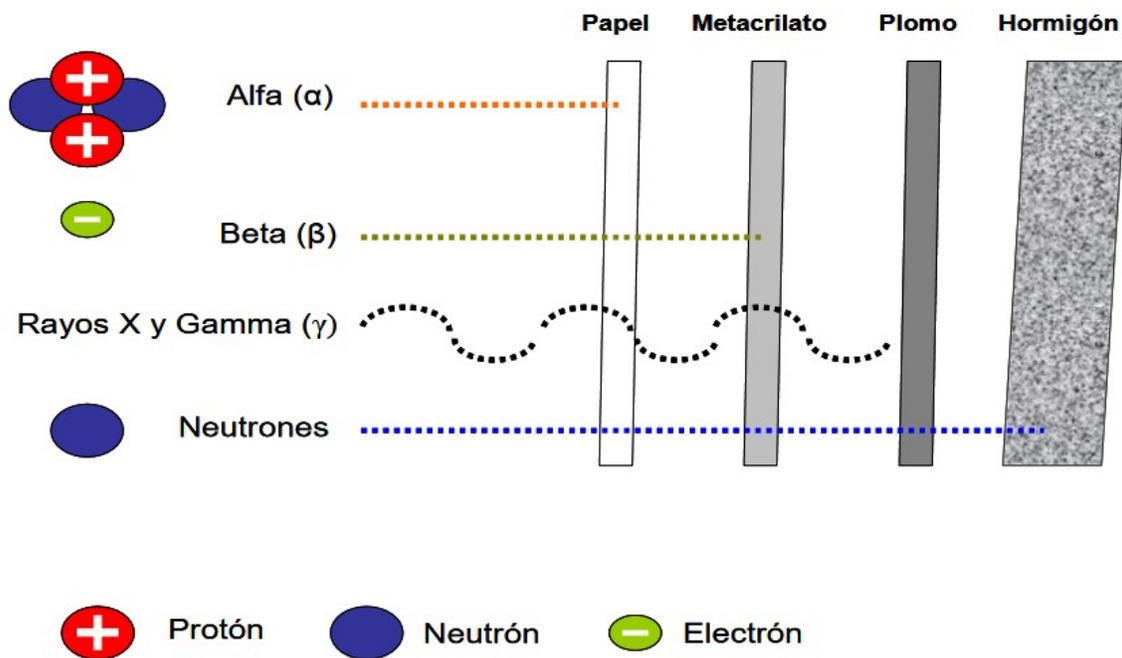


Figura 2. 16 Interacción de la radiación con la materia.

Los neutrones han contribuido poderosamente al desarrollo de la física nuclear porque son capaces de penetrar en la materia e interactuar con los núcleos atómicos sin verse afectados por la fuerza de Coulomb. Esto facilita el estudio de las fuerzas nucleares ya que la interacción neutrón-núcleo se debe casi exclusivamente a la interacción fuerte [CITATION Whi \l 2058]-

Por carecer de carga eléctrica, los neutrones no ionizan directamente, y al no ser desviados por los campos eléctricos de núcleos o electrones, son capaces en general de atravesar la materia. Los campos de neutrones, están presentes, particularmente en interiores de las contenciones de las instalaciones nucleares experimentales, o de potencia, además de unidades de tratamiento médico. Además de estar expuestos de manera natural, a causa de la radiación cósmica [CITATION Oir11 \l 2058] [CITATION Bak01 \l 2058].

La variación rápida de la sección eficaz con la energía del neutrón, ha incitado a clasificar los neutrones en categorías según su energía cinética y tipo de interacción. Los términos utilizados para describir los rangos de energía de los neutrones, fueron creados principalmente para distinguir como los neutrones interactúan con los materiales utilizados para las aplicaciones que utilizan fisión, tales como la energía nuclear, desarrollo de armas y producción de isótopos. Estos son relevantes para la discusión de sus efectos biológicos, además de cómo interactúan los neutrones con el cuerpo, ya que depende esto en gran medida de sus energías. A continuación se especifica los rangos en los cuales se encuentran los neutrones [CITATION Hei15 \l 2058]:

Tabla 2 Clasificación de los neutrones según su energía.

Neutrones	Rangos de energía
Térmicos	< 0,4 eV
Intermedios	0,4 eV – 10 keV
Rápidos	10 keV – 10 MeV
Relativistas	> 10MeV

Los detectores y la espectrometría de neutrones han jugado un papel esencial en la física nuclear fundamental y en sus aplicaciones. Los neutrones lentos no pueden detectarse con colisiones elásticas, porque la energía del núcleo que retrocede no supera al umbral de detección. Por otra parte, la detección de neutrones rápidos es un proceso con mucha menor eficiencia debido a la disminución de la sección eficaz cuando aumenta la energía, y la moderación de los neutrones se usa para resolver esta pérdida de eficiencia. La principal causa por la cual los neutrones pierden energía en el medio moderador, es por colisiones elásticas, y en menor grado por colisiones inelásticas [CITATION Kno99 \l 2058]

Los materiales que contienen hidrogeno, como el polietileno, y la parafina, donde los neutrones pierden una importante fracción de energía en una colisión elástica, son muy utilizados para moderar los neutrones rápidos, y aprovechar la más eficiente detección de los neutrones térmicos, siendo estos,

aquellos en equilibrio térmico con los núcleos del medio donde se encuentran. La pérdida de energía será mayor si se aumenta el espesor del moderador para aumentar el número de colisiones previas al a llegada de los neutrones al detector. De tal forma, que para mejorar la eficiencia de la detección de las distintas regiones de energía, se debe elegir adecuadamente el tamaño y la composición del moderador [CITATION Bak01 \l 2058].

2.3.1 Sistema espectrométrico de esferas Bonner

La espectrometría y dosimetría de neutrones, es de vital importancia dentro de la física de protección radiológica. Siendo la dosimetría de radiación de neutrones, una de las tareas más complicadas dentro del campo de protección radiológica. En el área de espectrometría de neutrones, existen una gran cantidad de dispositivos utilizados, y el más usado es el Sistema espectrométrico de Esferas Bonner (SEEB) [CITATION Bra60 \l 2058] [CITATION Bed10 \l 2058].

Para la elección del espectrómetro adecuado para aplicaciones en protección radiológica, la amplitud del espectro a medir puede llegar a ser más importante que la obtención de una gran resolución en energías. Esta es una de las razones por la cual el SEEB tiene un gran potencial [CITATION McD01 \l 2058].

El SEEB, también conocido como el espectrómetro multi-esferas, es el sistema más usado, principalmente por su respuesta isotrópica, el cual puede obtener el espectro de neutrones desde el rango de los neutrones térmicos, hasta los GeV, además que opera con una amplia variedad de detectores pasivos, el cual puede ser elegido según las características del campo de trabajo. El SEEB comprende de un detector de neutrones térmicos, que está localizado en el centro de un grupo de esferas de polietileno de alta densidad, de diámetro distinto, en pulgadas exactas o medias pulgadas.

Cada esfera, tienen una respuesta particular, siendo cada una sensible a diferente rango e energía, de tal forma que con la respuesta del grupo completo de esferas, nos arroja la llamada “matriz de respuesta” [CITATION Veg15 \l 2058] [CITATION Tho04 \l 2058]. Para una pequeña esfera, el grado de moderación es baja, capturando neutrones térmicos. Hay una probabilidad razonable de que los neutrones de baja de energía, lleguen al detector de neutrones térmicos, mientras que los neutrones de mayor energía escaparían. Mientras que para esferas más grandes, el grado de moderación es mayor, capaz de captar neutrones de mayor energía [CITATION Tho02 \l 2058]. En la siguiente figura se observa como la eficiencia de cada esfera varía según su diámetro.

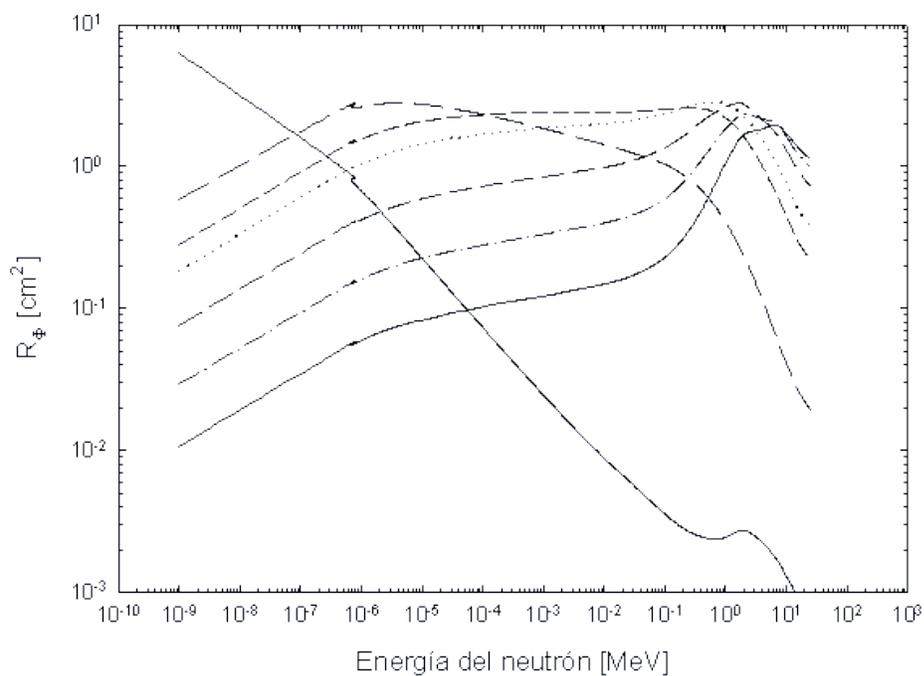


Figura 2. 17 Matriz de respuesta del SEEB

A partir de las lecturas provenientes del sistema, se puede derivar la información sobre el espectro de neutrones. La derivación de esta información no es simple, sino resolviendo la ecuación integro-diferencial de Fredholm de primer tipo [CITATION Tho02 \l 2058]. Cuando los neutrones de energía

E_i alcanzan la esfera de diámetro D_j los neutrones pierden energía, y alcanzan al detector produciendo una señal que se traduce en una tasa de conteo C_j . Al conjunto de eficiencias en función de la energía de los neutrones se le llama “matriz de respuesta”, la relación entre las tasas de conteo, en función del diámetro de la esfera $C(D)$, la matriz de respuesta $R(D, E)$ y el espectro de las muestras $\Phi_E(E)$, se muestra en la siguiente ecuación (Vega Carrillo, Wehring, otros., 1999)[CITATION Veg15 \l 2058]

$$C(D) = \int_{E_{\min}}^{E_{\max}} R(D, E) \Phi_E(E) dE \quad (2.6)$$

Y a continuación se muestra la ecuación 2.6 en su forma discreta.

$$C_j = \sum_{i=1}^m R_{i,j} \Phi_i \quad (2.7)$$

Donde m , es el número de esferas, C_j es la tasa de conteo del j -ésimo detector, $R_{i,j}$ es la matriz de respuesta del j -ésimo detector de neutrones en el i -ésimo intervalo de energía, y Φ_i es la fluencia de neutrones en el i -ésimo intervalo de energía [CITATION Veg15 \l 2058].

Debido a que el número de incógnitas es mayor al número de ecuaciones, se considera que el sistema está mal condicionado, y que tiene un número infinito de soluciones. Encontrar la solución que tenga un significado físico es una tarea de vital importancia [CITATION kar03 \l 2058][CITATION Veg05 \l 2058].

2.4. Dosimetría de neutrones

En el área de protección radiológica, conocer la “dosis equivalente”, se logra a través de instrumentos de detección o dosímetros personales. Las lecturas se usan para conocer el estado de los individuos, y sus riesgos, resultado de estar expuestos a la radiación. Los dosímetros personales usados, suelen estimar la “dosis personal equivalente”, mientras que las mediciones a través de instrumentos, estiman la “dosis ambiental equivalente”. Ambas mediciones, tiene la finalidad de proporcionar la información de las condiciones de trabajo en las cuales la gente está expuesta [CITATION Mar06 \l 2058].

Una vez el espectro de neutrones $\Phi_E(E)$ ha sido reconstruido, las dosis Δ se puede obtener, usando los coeficientes de conversión fluencias-a-dosis $\delta_\phi(E)$, como se muestra en la siguiente ecuación [CITATION Veg15 \l 2058].

$$\Delta = \int_{E_{\min}}^{E_{\max}} \delta_\phi(E) \Phi_E(E) dE \quad (2.8)$$

El uso de redes neuronales para resolver el problema de reconstruir el espectro de neutrones, y calcular la dosis equivalente, ha sido una herramienta que se ha estado utilizando los últimos años, como una herramienta novedosa. Aunque las RNA ofrecen muchos beneficios, no está libre de problemas. En trabajos previos, se utilizó las RNA de propagación inversa para resolver este problema [CITATION Rey14 \l 2058], y aunque los resultados fueron prometedores, la red sigue teniendo muchas variables que afectan el funcionamiento de la red, es por eso que, se mantiene la búsqueda de otras herramientas, que den buenos resultados y minimicen las variables que afecten a la red.

CAPITULO 3

MATERIALES Y METODOS

3.1. Redes neuronales de regresión generalizada

Las RNA se han utilizado en una amplia variedad de problemas, por su capacidad de aproximación o aprendizaje, de relaciones complejas, utilizando procesadores no lineales masivamente interconectados, y distribuidos en forma paralela. Se había estado utilizando el proceso de prueba y error para obtener los parámetros para el diseño de la red que sea capaz de resolver el problema de la reconstrucción del espectro de neutrones y el cálculo simultaneo de la dosis, aunque existen los riesgos de que la red no sea capaz de resolver el problema, ya que existen diferentes parámetros que se pueden controlar y otros que no, y no existe una regla que de los parámetros óptimos.

En trabajos anteriores se incursiono en las redes neuronales de propagación inversa (RNAPI), utilizando la metodología de diseño robusto de Taguchi, como método de optimización de RNA. El problema que sigue habiendo muchos factores que el usuario puede controlar, y otros que no. Por estos motivos, se ha seguido incursionando en nuevas arquitecturas, siendo las RNARG. Comparando una RNAPI con una RNARG, la red de regresión generalizada es mucho más veloz de ser entrenada, la cual entran en la categoría de redes neuronales probabilísticas.

En este trabajo, un grupo de redes neuronales de regresión generalizada fueron entrenadas para reconstruir el espectro de neutrones, utilizando una herramienta tecnología diseñada para este propósito. Con el fin de validar el funcionamiento de las RNARG, aplicado en la espectrometría de

neutrones, se utilizó una herramienta computacional para reconstruir el espectro de neutrones, basada en la tecnología RNARG, con un alto rendimiento y capacidad de generalización. La herramienta automatiza el entrenamiento, prueba, valida y procesa la información generada por el código, Después de entrenar y probar la red, la herramienta analiza, gráfica y guarda la información resultante [CITATION Mar16 \l 2058].

Además, con el fin de expandir la herramienta y que más grupos de investigación puedan usar esta tecnología, se entrenara, probara y validaran redes neuronales para reconstruir el espectro de neutrones, calcular las dosis, y resolviendo ambos problemas con la misma red, utilizando como entrada, las tasas de conteo del SEEB, de tres detectores de neutrones térmicos, dos sensores de Helio y uno de Litio.

3.2. Etapa de entrenamiento

Para el entrenamiento de las redes neuronales, se utilizó una herramienta codificada en el entorno de Matlab. Para el entrenamiento de la red, se utilizaron 251 casos compilados por la agencia internacional de energía atómica.

Con la finalidad de hacer una validación cruzada en las RNARG, se dividió los entrenamientos en dos grupos: pre-validación y de validación. En los entrenamientos pre-validación, será utilizando el 80% de los datos totales para el entrenamiento y 20% para la prueba, mientras que en los entrenamientos para la validación, se harán utilizando el 66% de entrenamiento y 34% de prueba.

Por la naturaleza de las RNARG, no requiere información que el usuario requiera modificar, de tal forma que en la herramienta diseñada en matlab, solo son necesario las rutas de los documentos para entrenar las redes neuronales. En la figura 3.1, se muestra la primera pantalla de la herramienta, donde da la opción de entrenar, graficar y guardar, siendo la primera opción para proseguir.

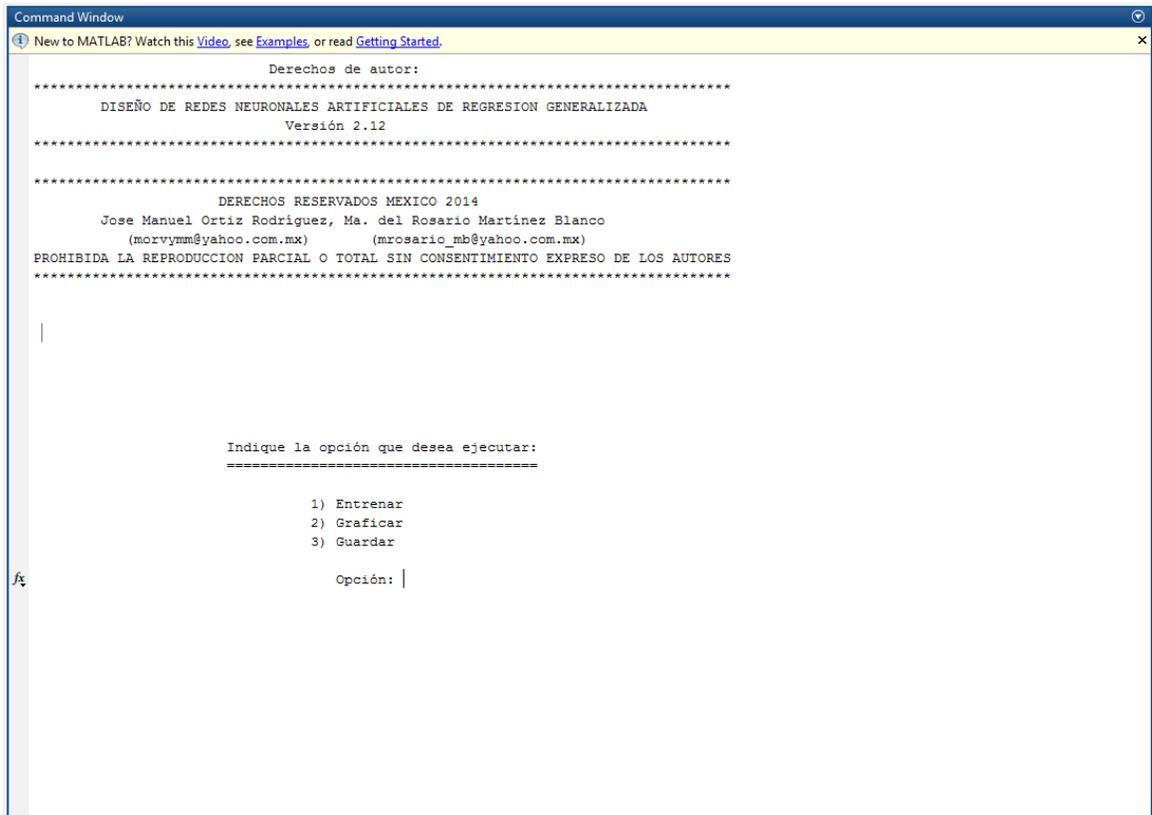


Figura 3. 1 Pantalla de inicio de la herramienta para entrenar las RNARG.

En la figura 3.2 se muestra la siguiente pantalla, se observa cual es la información que requiere el programa para los entrenamientos. Mientras que en la figura 3.3 se observa que la herramienta pide los datos para nombrar a la red, pregunta si quiere que la generación de las matrices de entrenamiento y de prueba serán aleatorias y sobre qué información del entrenamiento será guardado y graficado.

```
Command Window
New to MATLAB? Watch this Video, see Examples, or read Getting Started.
INGRESE LA RUTA COMPLETA Y NOMBRE DE ARCHIVO CON EXTENSIÓN

V.gr. C:\ruta\archivo.xls

Primera matriz de entrada y salida

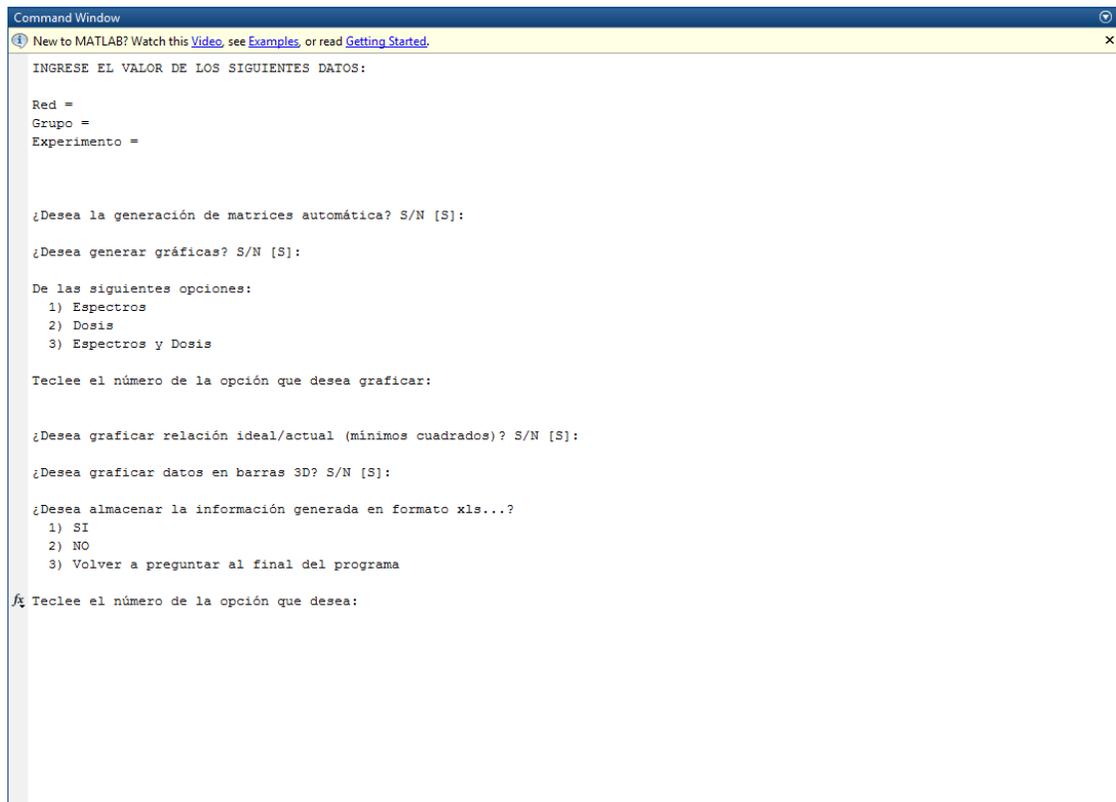
Ruta de entrada :
Ruta de salida :
¿Tiene eje específico la matriz de salida? S/N [S]:
Ruta del eje "X":

¿Desea ingresar otra matriz de entrada y/o salida? S/N [S]:
¿Desea aumentar los datos de la matriz...
    ..de entrada? S/N [S]:
    ..de salida? S/N [S]:
¿Tiene eje específico la matriz de salida? S/N [S]:

Segunda matriz de entrada y/o salida

Ruta de entrada :
Ruta de salida :
fx Ruta del eje "X":
```

Figura 3. 2. Segunda pantalla de la herramienta para entrenar RNARG.



```
Command Window
New to MATLAB? Watch this Video, see Examples, or read Getting Started.
INGRESE EL VALOR DE LOS SIGUIENTES DATOS:
Red =
Grupo =
Experimento =

¿Desea la generación de matrices automática? S/N [S]:
¿Desea generar gráficas? S/N [S]:
De las siguientes opciones:
1) Espectros
2) Dosis
3) Espectros y Dosis
Teclee el número de la opción que desea graficar:
¿Desea graficar relación ideal/actual (mínimos cuadrados)? S/N [S]:
¿Desea graficar datos en barras 3D? S/N [S]:
¿Desea almacenar la información generada en formato xls...?
1) SI
2) NO
3) Volver a preguntar al final del programa
fx Teclee el número de la opción que desea:
```

Figura 3. 3 Tercera pantalla, donde pide los datos para nombrar la red, la generación de los datos de entrenamiento y prueba, y sobre guardar y graficar la información resultante.

Para los datos de entrada, se utilizaron las matrices de las tasas de conteo de tres sensores distintos del SEEB En la siguiente tabla se muestra las esferas que contiene cada matriz en pulgadas

Tabla 3 Esferas que constan el SEEB de tres laboratorios.

No. esfera	De	Diámetro en pulgadas de la matriz 3He PTB	Diámetro en pulgadas de la matriz 3He LANL	Diámetro en pulgadas de la matriz Lil GSF
1		Al desnudo	3	Al desnudo
2		2.5	4	2
3		3	5	3
4		3.5	6	5
5		4	8	6
6		4.5	9	8
7		5	9 + pb	10
8		6	12	12
9		7	12 + pb	15
10		8	18	18
11		9.5	18 + pb	
12		10		
13		12		
14		15		
15		18		

Como se observa en la tabla anterior, el primer sistema consta de un detector de Helio proveniente de las instalaciones de PTB en Braunschweig, Alemania, otro detector de Helio del LANL (de sus siglas en inglés: Los Alamos National Laboratory), y un último de Litio proveniente del centro de investigación para el medio ambiente y la salud de Neuherberg/Munich, Alemania. Siendo los datos de entrada provenientes del SEEB, de 15 para el detector de Helio de PTB, 11 para el de Helio de LANL y 10 para el de Litio de GSF.

Haciendo los entrenamientos con los 10 datos, posteriormente reduciendo el número de entradas a siete, dos y un solo dato de entrenamiento. La finalidad principal de reducir el sistema, es para darle portabilidad y facilidad a utilizar el sistema completo.

La ruta de entrada que requiere la herramienta, es de las tasas de conteo de las matrices de helio y litio, la ruta de salida, son los datos del espectro de neutrones, de las dosis o de ambas. El eje X que requiere el sistema, son los grupos de energía en el cual se desplegara el espectro de neutrones, siendo de 60 grupos de energía.

En la última parte antes del entrenamiento, requiere la información para darle el nombre a la red, pide el número de la red, número de grupo y de experimento. Para la siguiente pregunta, que es la generación de matrices automáticas, será diferente según sea la etapa pre-validación y para la validación, en el caso de pre-validación, será automática, y en el caso para la validación, no lo es, ya que para este caso, los grupos de entrenamiento y prueba son diferentes, de tal forma, que una vez entrenada la red, con los valores de 80% entrenamiento y 20% prueba, se hará la validación con tres grupos, de 33% dos grupos para entrenamiento y uno de 34%, de tal forma, que al entrenar la red, se separaran los datos de entrenamiento y prueba manualmente, según hayan quedado en el entrenamiento pre-validación. Esta separación manual se hará en archivos .xls, quedando 66% de entrenamiento y 34% para la prueba.

La siguiente pregunta, se seleccionara dependiendo del entrenamiento, ya sea para reconstruir el espectro de neutrones, obtener las dosis, o ambos casos al mismo tiempo.

En las siguientes imágenes, se muestra el proceso con la información para los entrenamientos de la red.

```

Command Window
New to MATLAB! Watch this Video, see Examples, or read Getting Started.
INGRESE LA RUTA COMPLETA Y NOMBRE DE ARCHIVO CON EXTENSIÓN
V.gr. C:\ruta\archivo.xls

Primera matriz de entrada y salida
Ruta de entrada : C:\Users\LIDTIA\Documents\Entrenamientos\RNA RG\2-Etapa DOS- Conversion espectros letargia-energía, calculo tasas de conteo, desarrollos tecnologicos\Tasas de conteo de la fuente SHE-PTB.xls
Ruta de salida : C:\Users\LIDTIA\Documents\Entrenamientos\RNA RG\2-Etapa DOS- Conversion espectros letargia-energía, calculo tasas de conteo, desarrollos tecnologicos\Espectros en energía.xls
¿Hace eje específico la matriz de salida? S/N [S]:
Ruta del eje "X": sun('C:\Users\LIDTIA\Documents\MATLAB\RDGRANN_V08_Solo_espectros.m')
¿Desea ingresar otra matriz de entrada y/o salida? S/N [S]: n

```

Figura 3. 4 Pantalla de la herramienta, donde se ingresan las rutas de los archivos.

```

Command Window
New to MATLAB! Watch this Video, see Examples, or read Getting Started.
INGRESE EL VALOR DE LOS SIGUIENTES DATOS:
Red = 1
Grupo = 1
Experimento = 1

¿Desea la generación de matrices automática? S/N [S]:
¿Desea generar gráficas? S/N [S]:
De las siguientes opciones:
1) Espectros
2) Dosis
Teclee el número de la opción que desea graficar: 1

¿Desea graficar relación ideal/actual (mínimos cuadrados)? S/N [S]:
¿Desea graficar datos en barras 3D? S/N [S]:
¿Desea almacenar la información generada en formato xls...?
1) SI
2) NO
3) Volver a preguntar al final del programa
Teclee el número de la opción que desea: 3

```

Figura 3. 5 Pantalla de la herramienta donde se ingresa nombre de la red, y donde se pide la generación de las matrices y de guardar y graficar la información final.

```


Command Window
New to MATLAB! Watch this Video, see Examples, or read Getting Started.
DATOS INGRESADOS PARA EL ENTRENAMIENTO DE LA RED rlglexl
*****
CARGANDO DATOS DE ENTRENAMIENTO...
PROCESANDO DATOS DE ENTRADA Y SALIDA ...

Warning: Could not start Excel server for import, 'basic' mode will be used. Refer to HELP XLSREAD for more information.
> In xlsread at 187
In RDGRANN_V08_Solo_espectros at 265
In sun at 63
Warning: Could not start Excel server for import, 'basic' mode will be used. Refer to HELP XLSREAD for more information.
> In xlsread at 187
In RDGRANN_V08_Solo_espectros at 267
In sun at 63
Warning: Could not start Excel server for import, 'basic' mode will be used. Refer to HELP XLSREAD for more information.
> In xlsread at 187
In RDGRANN_V08_Solo_espectros at 270
In sun at 63

Generando matrices...
Warning: This is an obsolete function and may be removed in the future. Please use RANDI instead.
> In randint at 40
In RDGRANN_V08_Solo_espectros at 616
In sun at 63
Warning: This is an obsolete function and may be removed in the future. Please use RANDI instead.
> In randint at 40
In RDGRANN_V08_Solo_espectros at 620
In sun at 63
Warning: This is an obsolete function and may be removed in the future. Please use RANDI instead.
> In randint at 40
In RDGRANN_V08_Solo_espectros at 620
In sun at 63
Warning: This is an obsolete function and may be removed in the future. Please use RANDI instead.
> In randint at 40
In RDGRANN_V08_Solo_espectros at 620
In sun at 63

```

Figura 3. 6 Pantalla de la herramienta, durante el entrenamiento de la red.



```
Command Window
New to MATLAB? Watch this Video, see Examples, or read Getting Started.

Tiempo de entrenamiento      : 0.037801 seg.
Desempeño de la red         : 0.000315497

RED GENERAL
Chi cuadrada mínima        : 0.066324
Chi cuadrada máxima        : 7.00834
Chi cuadrada promedio       : 0.840439

Correlación mínima         : 0.206312
Correlación máxima         : 0.989365
Espectros para ajuste      : 9

¿Desea almacenar información generada? [S]:
```

Figura 3. 7 Pantalla de la herramienta, donde la red ya fue entrenada y entrega los resultados como desempeño, correlación y chi cuadrada.

4. Resultados

4.1. Resultados con matriz 3He de PTB con 15, 2 y 1 esfera Bonner.

En la tabla 4.1 se observa los resultados de la reconstrucción del espectro de neutrones, y en la tabla 4.2 los resultados de las dosis obtenidas, de todos los entrenamientos. Utilizando como datos de entrada, las tasas de conteo provenientes de un SEEB con un detector de He, de las instalaciones de PTB en Braunschweig, Alemania.

Tabla 4 Resultados de entrenamientos con el SEEB, con un detector de He, de PTB, para la reconstrucción del espectro.

Información	15 esferas	2 esferas	Esfera de 5 pulgadas	Esfera de 8 pulgadas
Tiempo de entrenamiento	0.10394 s	0.09223 s	0.11910796 s	0.092134
Desempeño de la red	0.00021927	0.00028673	0.00049318	0.0005146
Promedio de CHI cuadrada	0.90742514	118.036759	23.6897	18.9716
Correlación mínima	0.5079015	0.0412444	0.15928398	-0.304879
Correlación máxima	0.99978002	0.98220499	0.90503827	0.953744
Correlación promedio	0.85544703	0.75066491	0.59825342	0.61109

Tabla 5 Resultados de entrenamientos con el SEEB, con un detector de He, de PTB para el cálculo de las dosis.

Información	15 esferas	2 esferas	Esfera de 5 pulgadas	Esfera de 8 pulgadas
Tiempo de entrenamiento	0.09747 s	0.093241 s	0.20194 s	0.088152 s
Desempeño de la red	0.00000135	0.00000389	0.00005514	0.00002117
Promedio de CHI cuadrada	0.0018881	0.00471269	0.21993163	0.0528706
Correlación mínima	0.90922224	0.82376084	0.77371405	0.70667662
Correlación máxima	0.99990553	0.99995784	0.99795553	0.99960103
Correlación promedio	0.99299547	0.98165291	0.96169149	0.936763

4.1.1. Resultados de ^3He de PTB con matriz completa de entrada.

En las siguientes figuras, se muestra el mejor y el peor caso de los entrenamientos para reconstruir el espectro de neutrones, y además el cálculo de la dosis, con 15 datos de entrada, provenientes del SEEB, con un detector de He, del PTB en Alemania. En las figuras 4.1 y 4.2, se observa el mejor y el peor caso de reconstrucción del espectro de neutrones, mientras que en el 4.3 y 4.4 se muestra el mejor y peor caso para calcular las dosis. Se eligió el mejor y peor caso según su correlación, el cual para el mejor caso fue de 0.99978002 y el peor de 0.5079015, para la reconstrucción del espectro, mientras que para el mejor caso fue de 0.99990553 y para el peor de 0.90922224, para el cálculo de las dos.

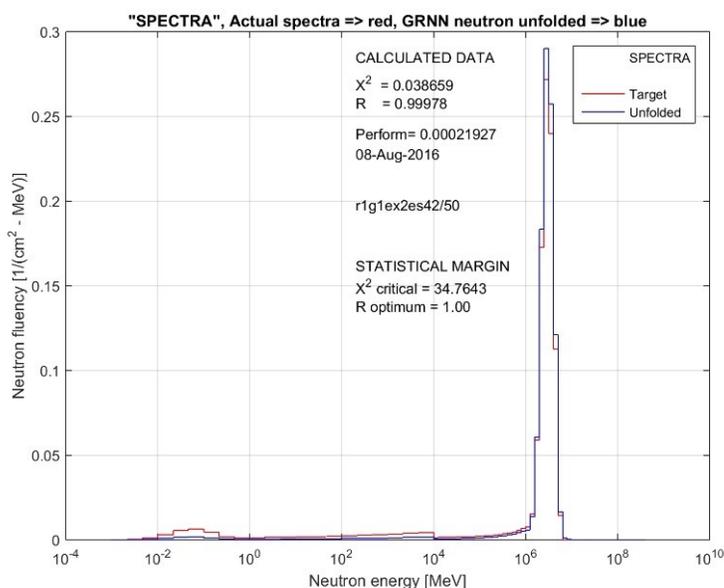


Figura 4. 1 El mejor espectro reconstruido utilizando las 15 tasas de conteo del sistema de PTB.



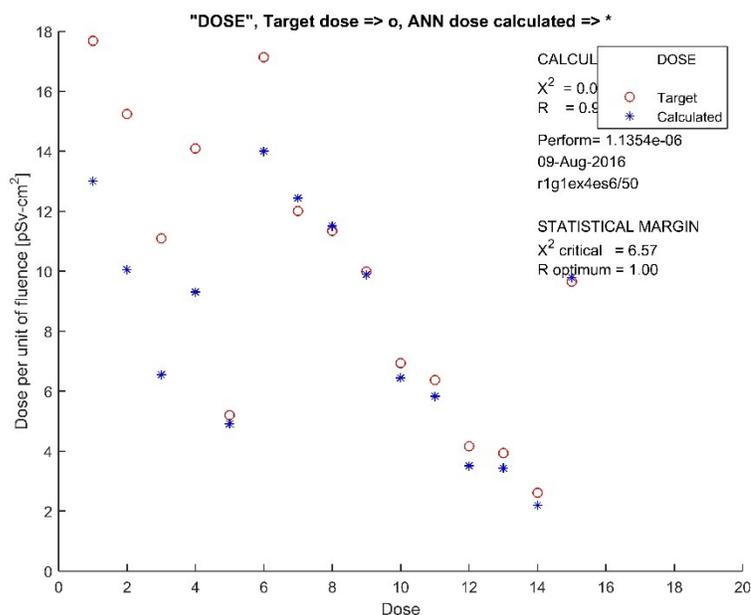


Figura 4. 4 El mejor caso para calcular las dosis utilizando las 15 tasas de conteo del sistema de PTB.

4.1.2. Resultados de ³He de PTB con dos esferas como dato de entrada.

En las siguientes figuras, se muestra el mejor y el peor caso de los entrenamientos para reconstruir el espectro de neutrones, y el mejor y peor caso con el cálculo de las dosis, con dos datos de entrada, siendo las tasas de conteo provenientes de las esferas de cinco y ocho pulgadas del SEEB, con un detector de He, proveniente de PTB en Alemania. En las figuras 4.5 y 4.6, se observa el mejor y el peor caso de reconstrucción del espectro de neutrones. Mientras que las figuras 4.7 y 4.8 se observa el mejor y peor caso con una red que da el cálculo de las dosis. Se eligió el mejor y peor caso según su correlación, el cual para el mejor caso fue de 0.98220499 y el peor de 0.0412444 para la red que

reconstruye el espectro de neutrones, mientras que la que da el cálculo de las dosis es de 0.99995784 para el mejor caso y para el peor de 0.82376084.

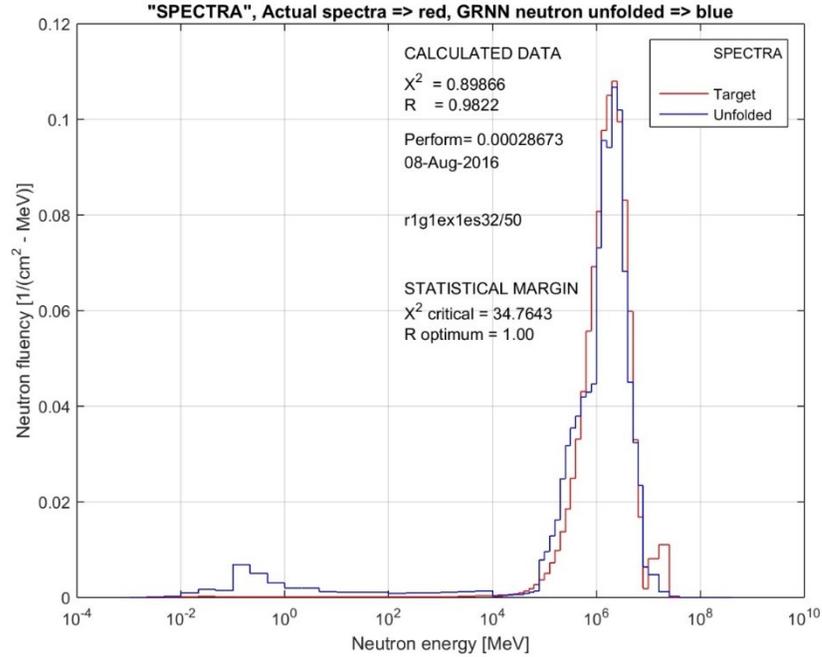


Figura 4. 5 El mejor espectro reconstruido utilizando dos tasas de conteo del sistema de PTB.

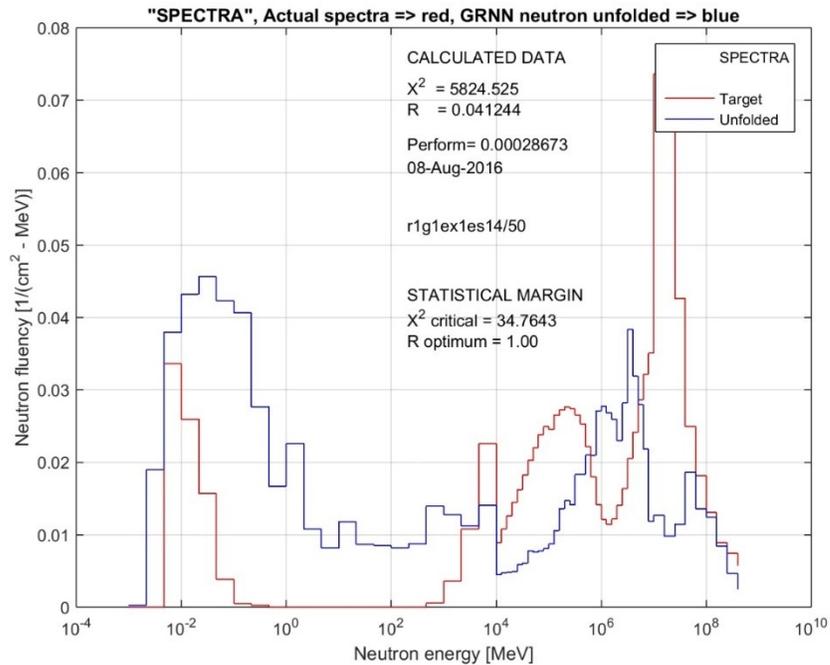


Figura 4. 6 El pro espectro reconstruido utilizando dos tasas de conteo del sistema de PTB.

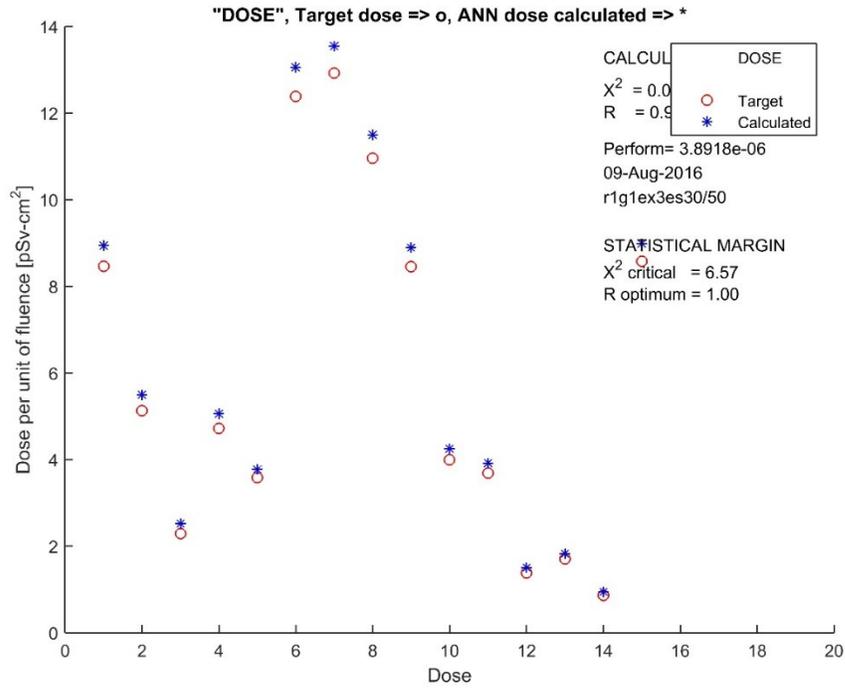


Figura 4. 7 El mejor caso para calcular las dosis utilizando dos tasas de conteo del sistema de PTB

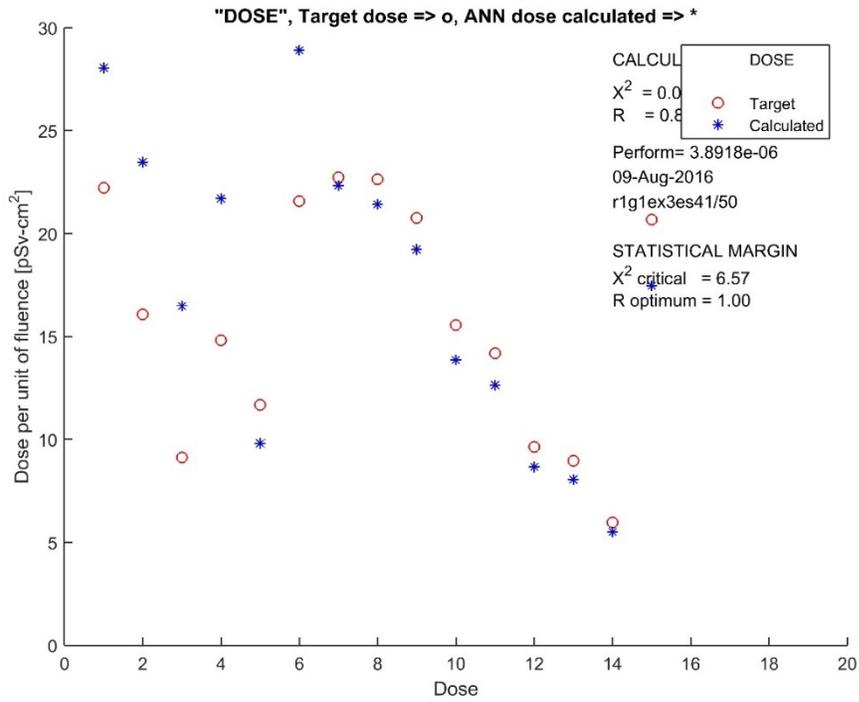


Figura 4. 8. El peor caso para calcular las dosis utilizando dos tasas de conteo del sistema de PTB

4.1.3. Resultados de ^3He de PTB con la esfera de cinco pulgadas como dato de entrada.

En las siguientes figuras, se muestra el mejor y el peor caso de los entrenamientos para reconstruir el espectro de neutrones y los del cálculo de las dosis, utilizando un solo dato de entrada, siendo la tasa de conteo provenientes de la esfera de cinco pulgadas del SEEB, con un detector de He, de PTB en Alemania. En las figuras 4.9 y 4.10, se observa el mejor y el peor caso de reconstrucción del espectro de neutrones mientras que en las figuras 4.11 y 4.12 se muestran los casos del cálculo de las dosis. Se eligió el mejor y peor caso según su correlación, el cual para el mejor caso fue de 0.90503827 y el peor de 0.15928398 para los casos de reconstrucción del espectro, mientras que para el mejor caso del cálculo de las dosis es 0.99795553 y el peor de 0.77371405.

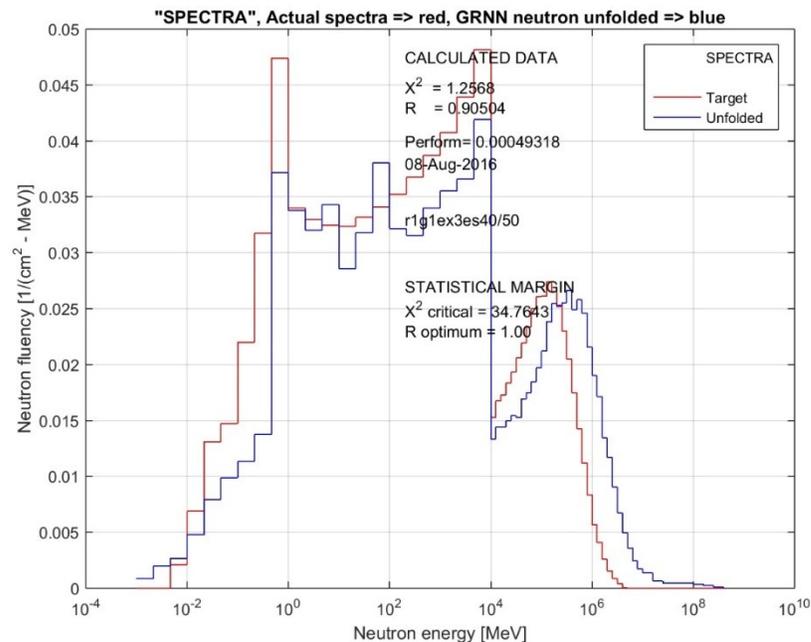


Figura 4. 9 El mejor espectro reconstruido utilizando la tasa de conteo de la esfera de cinco pulgadas del sistema de PTB.

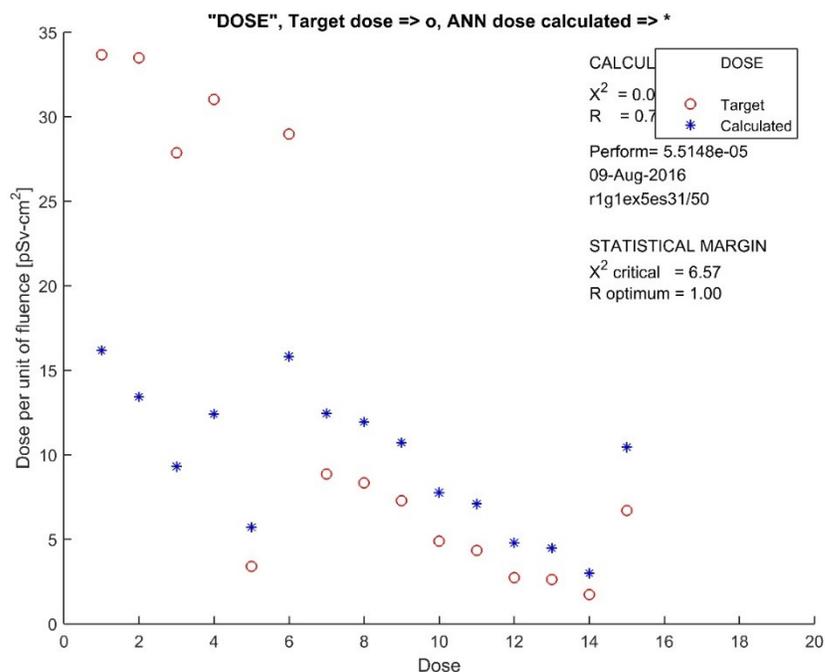


Figura 4. 12 El peor caso para calcular las dosis utilizando la tasa de conteo proveniente de la esfera de cinco pulgadas del SEEB de la matriz de PTB

4.1.4. Resultados de ³He de PTB con la esfera de ocho pulgadas como dato de entrada.

En las siguientes figuras, se muestra el mejor y el peor caso de los entrenamientos para reconstruir el espectro de neutrones, y los entrenamientos para el cálculo de las dosis, con un solo dato de entrada, siendo la tasa de conteo provenientes de la esfera de ocho pulgadas del SEEB, con un detector de He, de PTB en Alemania. En las figuras 4.13 y 4.14, se observa el mejor y el peor caso de reconstrucción del espectro de neutrones mientras que en las figuras 4.14 y 4.15 se observan el mejor y peor caso del cálculo de las dosis. Se eligió el mejor y peor caso según su correlación, el cual para el mejor caso fue

de 0.95374404y el peor de -0.30487904 del a red para reconstruir el espectro de neutrones, y de 0.9996013 para el mejor caso de la red del cálculo de las dosis y el peor de 0.70667662.

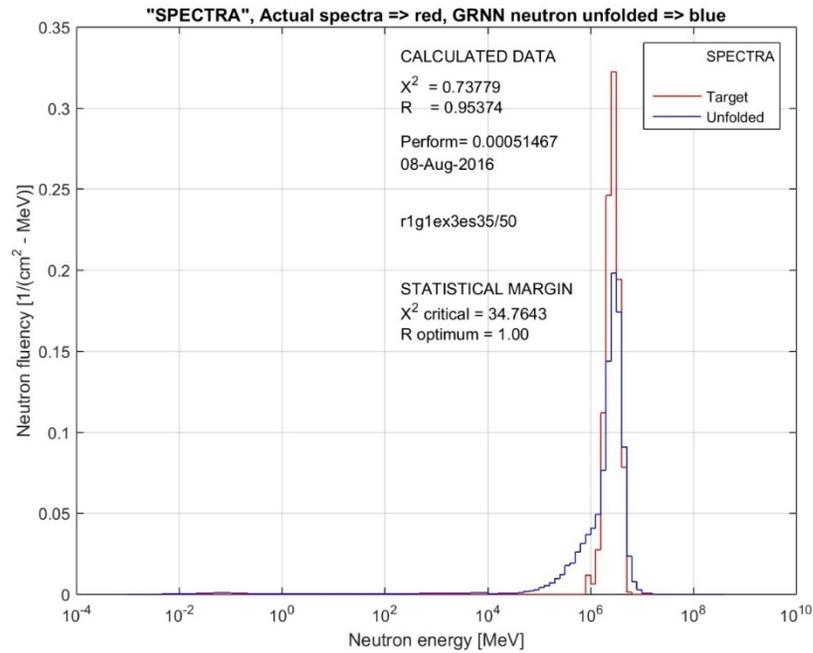


Figura 4. 13 . El mejor espectro reconstruido utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema de PTB.

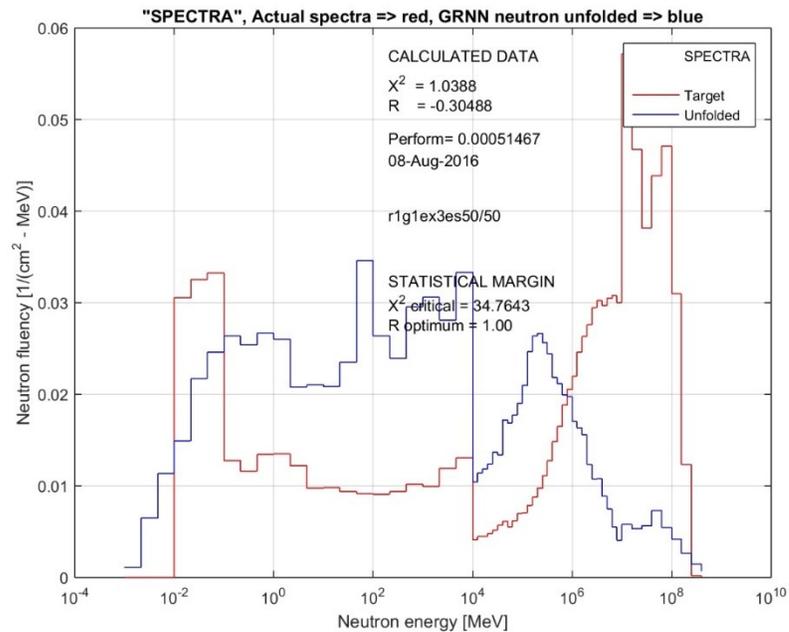


Figura 4. 14. El peor espectro reconstruido utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema de PTB.

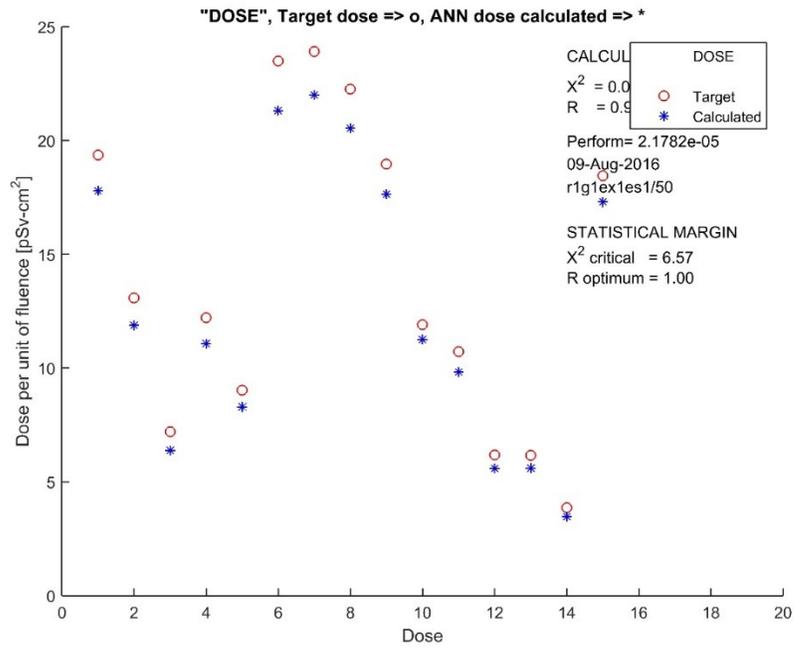


Figura 4. 15 El mejor caso para calcular las dosis utilizando la tasa de conteo proveniente de la esfera de ocho pulgadas del SEEB de la matriz de PTB

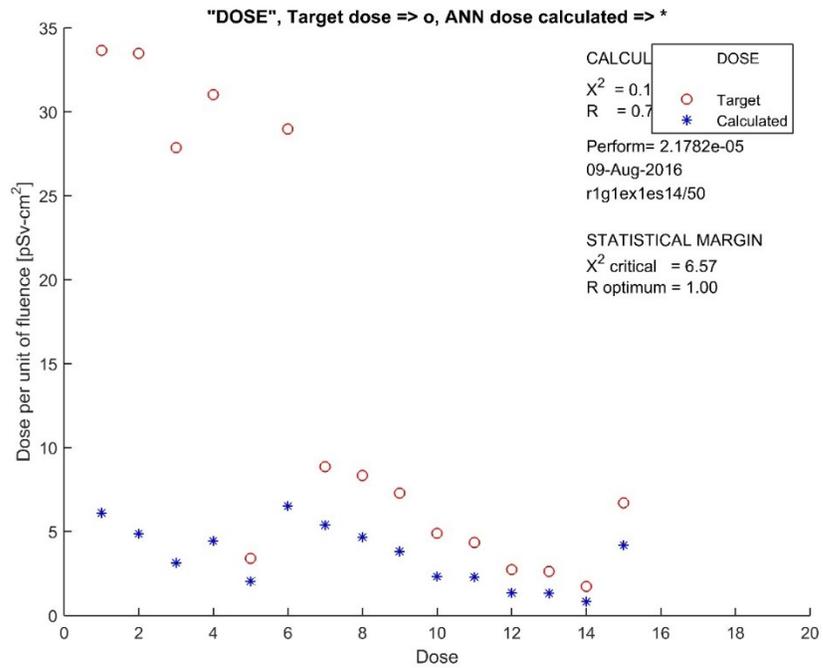


Figura 4. 16. El peor caso para calcular las dosis utilizando la tasa de conteo proveniente de la esfera de ocho pulgadas del SEEB de la matriz de PTB

4.2. Resultados con matriz con detector de ^3He del LANL con 11, 2 y 1 esfera Bonner.

En la Tabla 4.3 se observa los resultados de todos los entrenamientos de las redes para resolver el problema de la reconstrucción del espectro de neutrones, mientras que en la tabla 4.4, se observan los resultados de las redes para el cálculo de las dosis, utilizando como datos de entrada, las tasas de conteo provenientes de un SEEB con un detector de He, de las instalaciones de LANL en Los Alamos.

Tabla 6. Resultados de entrenamientos de las redes para la reconstrucción del espectro de neutrones con el SEEB, con un detector de HE, del LANL.

Información	11 esferas	2 esferas	Esfera de 5 pulgadas	Esfera de 8 pulgadas
Tiempo de entrenamiento	0.116787 s	0.112379 s	0.138117 s	0.21633 s
Desempeño de la red	0.0002665	0.000264	0.000616	0.00040998
Promedio de CHI cuadrada	4.443094	4.65758	15.094299	10.3561511
Correlación	0.4889839	0.21509297	-0.217143	0.148824

mínima				
Correlación	0.9968914	0.9917271	0.9307128	0.954348
máxima				
Promedio de la correlación	0.82953069	0.7998198	0.57143287	0.65462195

Tabla 7. Resultados de entrenamientos de las redes para el cálculo de las dosis con el SEEB, con un detector de HE, del LANL.

Información	11 esferas	2 esferas	Esfera de 5 pulgadas	Esfera de 8 pulgadas
Tiempo de entrenamiento	0.120465 s	0.11983 s	0.1784122 s	0.16232 s
Desempeño de la red	0.0000009	0.000003	0.00005410	0.00001663
Promedio de CHI cuadrada	0.0017281	0.0040251	0.1754155	0.0367764
Correlación mínima	0.93164522	0.821498	0.80570844	0.810702
Correlación máxima	0.99998391	0.999992	0.99951883	0.99916571
Promedio de la correlación	0.9949182	0.9880043	0.96640193	0.9420086

4.2.1. Resultados de ^3He de LANL con matriz completa de entrada.

En las figuras 4.17 y 4.18, se muestra el mejor y el peor caso de los entrenamientos para reconstruir el espectro de neutrones, mientras que en la 4.19 y 4.20 el mejor y peor caso del cálculo de las dosis, utilizando 11 datos de entrada, provenientes del SEEB, con un detector de He, del LANL en Los Alamos. Se eligió el mejor y peor caso según su correlación, el cual para el mejor caso fue de 0.9968914 y el peor de 0.4889839 para la reconstrucción del espectro de neutrones, mientras que el mejor y peor caso para el cálculo de las dosis es de 0.99998391 y 0.93164522 respectivamente.

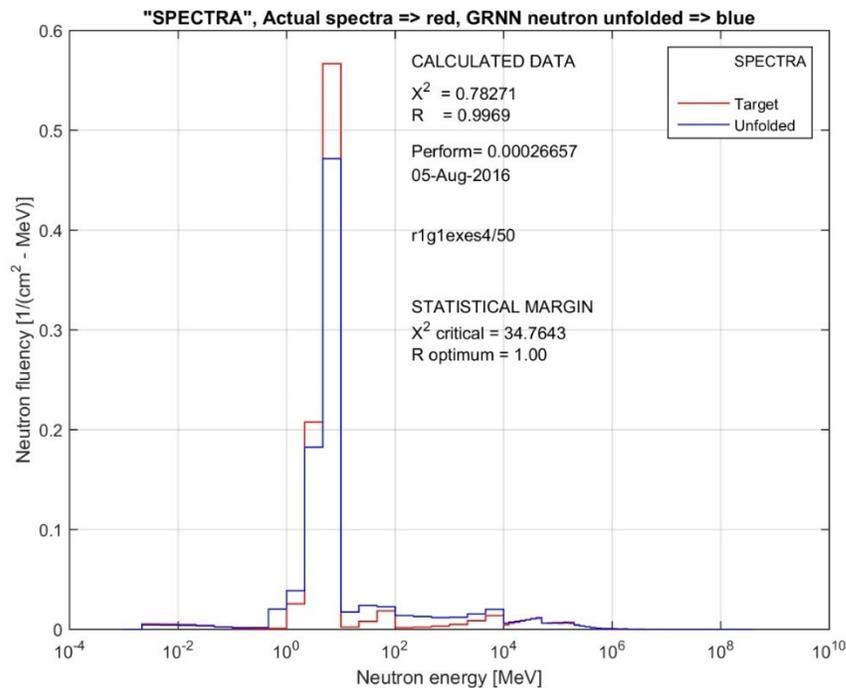


Figura 4. 17 El mejor espectro reconstruido de neutrones, utilizando las 11 tasas de conteo del sistema de LANL.

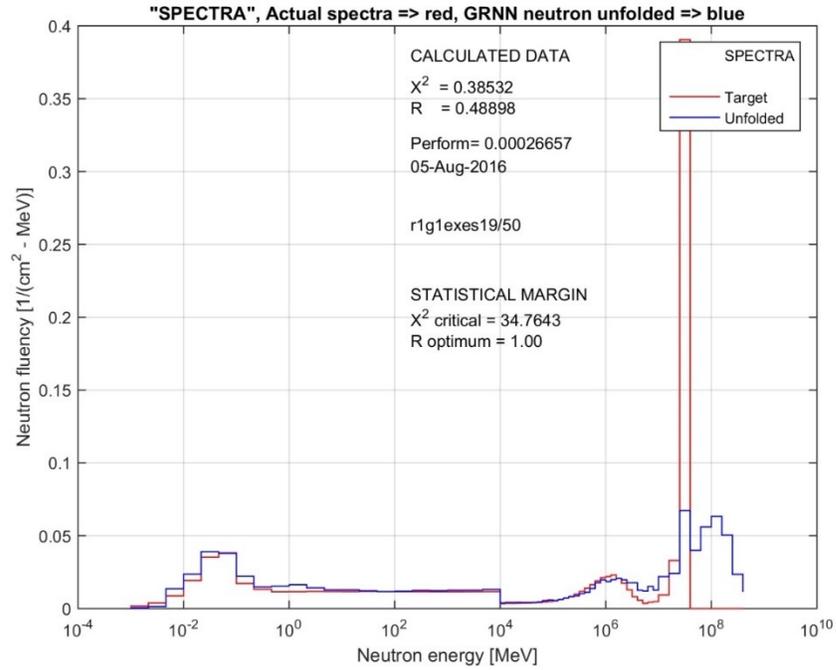


Figura 4. 18 El peor espectro reconstruido de neutrones, utilizando las 11 tasas de conteo del sistema de LANL.

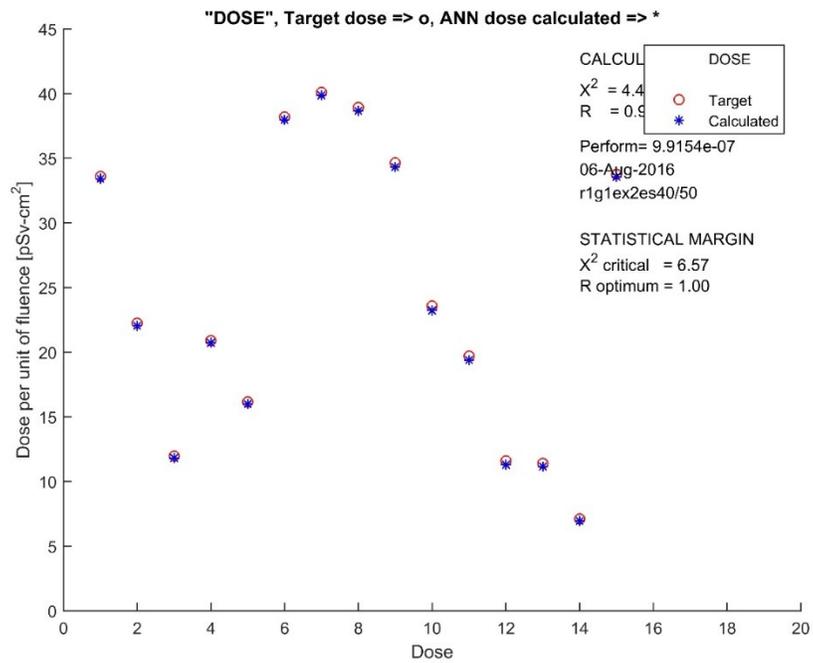


Figura 4. 19 El mejor caso para calcular las dosis utilizando la tasa de conteo, utilizando las 11 tasas de conteo del SEEB de la matriz de LANL

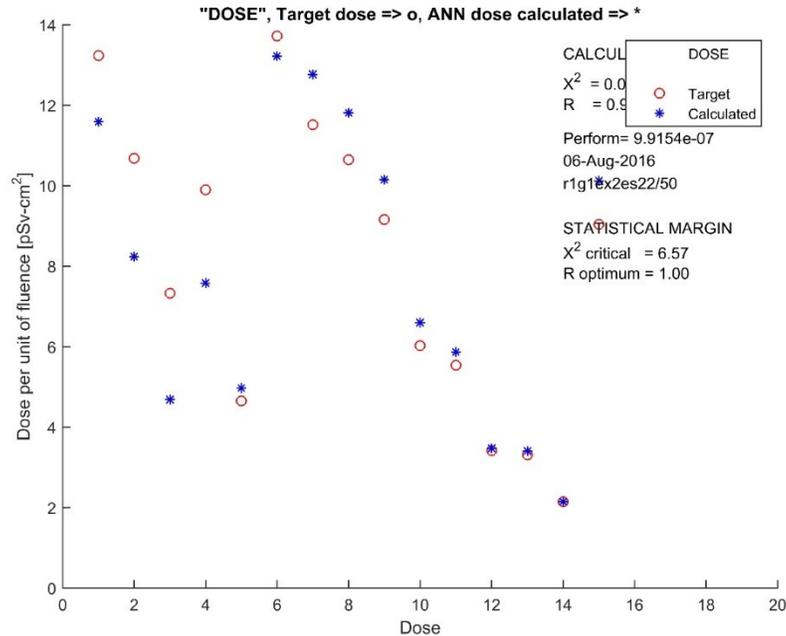


Figura 4. 20 El mejor caso para calcular las dosis utilizando la tasa de conteo, utilizando las 11 tasas de conteo del SEEB de la matriz de LANL

4.2.2. Resultados de ³He de LANL con dos esferas como dato de entrada.

En las figuras 4.21 y 4.22, se muestra el mejor y el peor caso de los entrenamientos para reconstruir el espectro de neutrones, mientras que en la 4.23 y 4.24 el mejor y peor caso del cálculo de las dosis, utilizando dos datos de entrada, provenientes del SEEB, con un detector de He, del LANL en Los Alamos. Se eligió el mejor y peor caso según su correlación, el cual para el mejor caso fue de 0.9917271 y el peor de 0.21509297 para la reconstrucción del espectro de neutrones, mientras que el mejor y peor caso para el cálculo de las dosis es de 0.999992 y 0.821498 respectivamente.

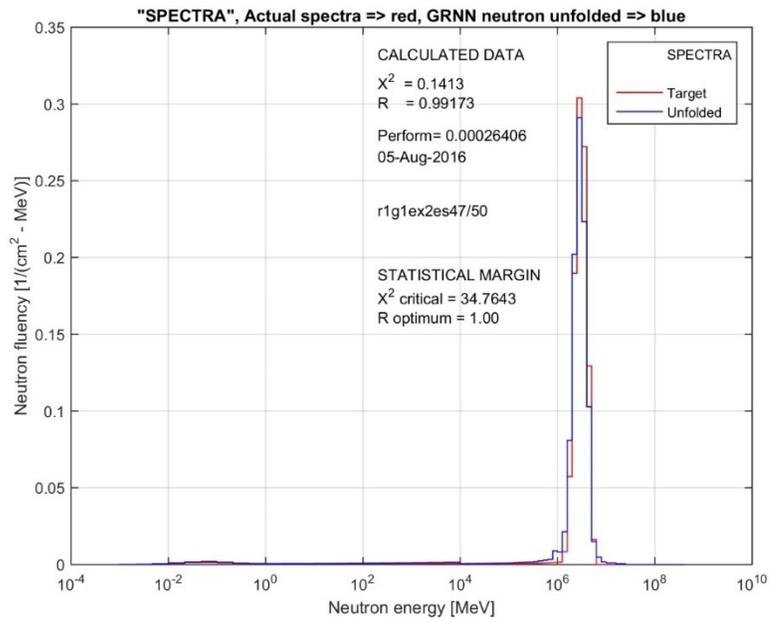


Figura 4. 21. El mejor espectro reconstruido utilizando dos tasas de conteo del sistema de LANL.

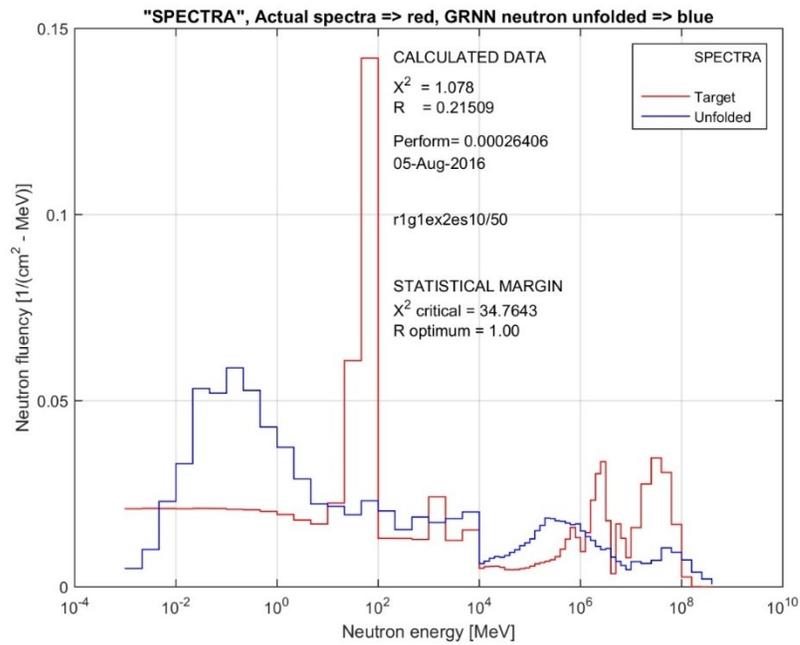


Figura 4. 22. El peor espectro reconstruido utilizando dos tasas de conteo del sistema de LANL.

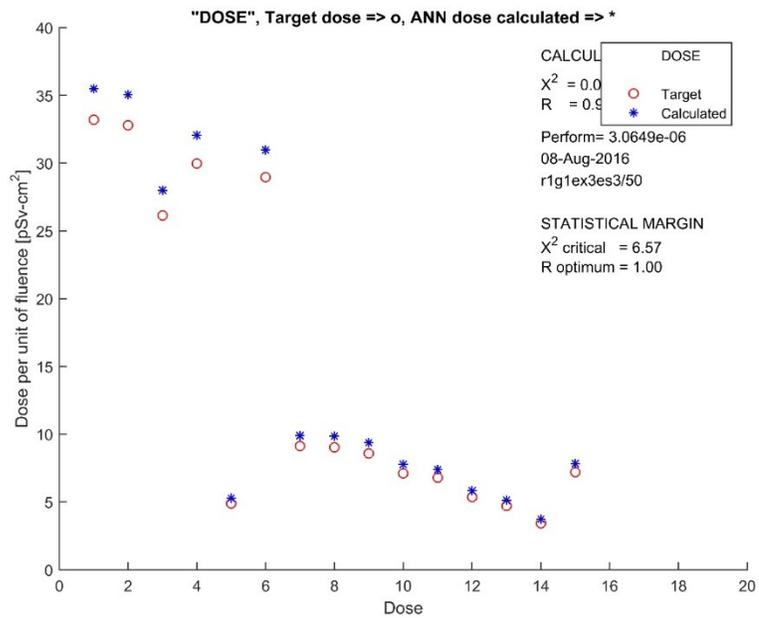


Figura 4. 23. El mejor cálculo de las dosis utilizando dos tasas de conteo del sistema de LANL.

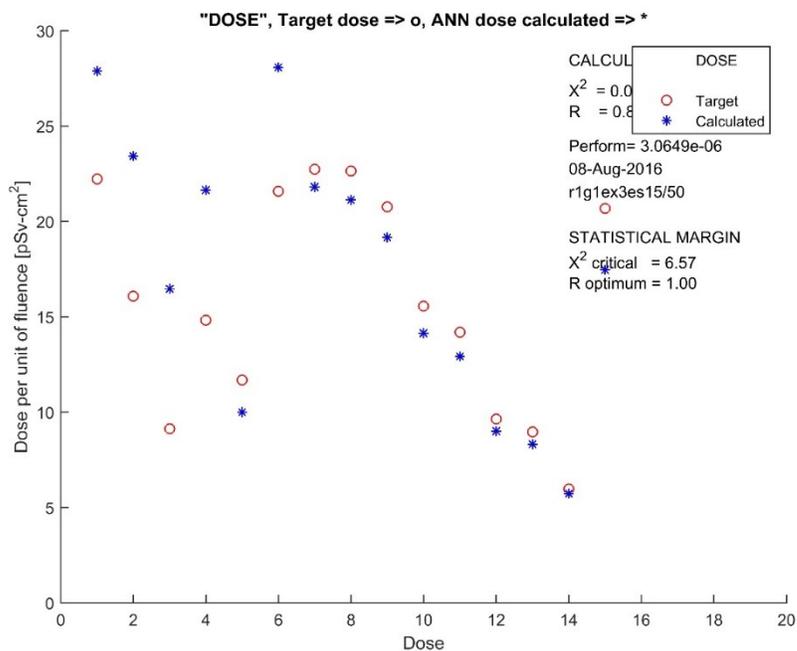


Figura 4. 24 El mejor cálculo de las dosis utilizando dos tasas de conteo del sistema de LANL.

4.2.3. Resultados de ^3He de LANL con esfera de cinco pulgadas como dato de entrada.

En las figuras 4.25 y 4.26, se muestra el mejor y el peor caso de los entrenamientos para reconstruir el espectro de neutrones, mientras que en la 4.27 y 4.28 el mejor y peor caso del cálculo de las dosis, utilizando la esfera de cinco pulgadas de entrada, provenientes del SEEB, con un detector de He, del LANL en Los Alamos. Se eligió el mejor y peor caso según su correlación, el cual para el mejor caso fue de 0.9307128 y el peor de -0.217143 para la reconstrucción del espectro de neutrones, mientras que el mejor y peor caso para el cálculo de las dosis es de 0.99951883 y 0.80570844 respectivamente.

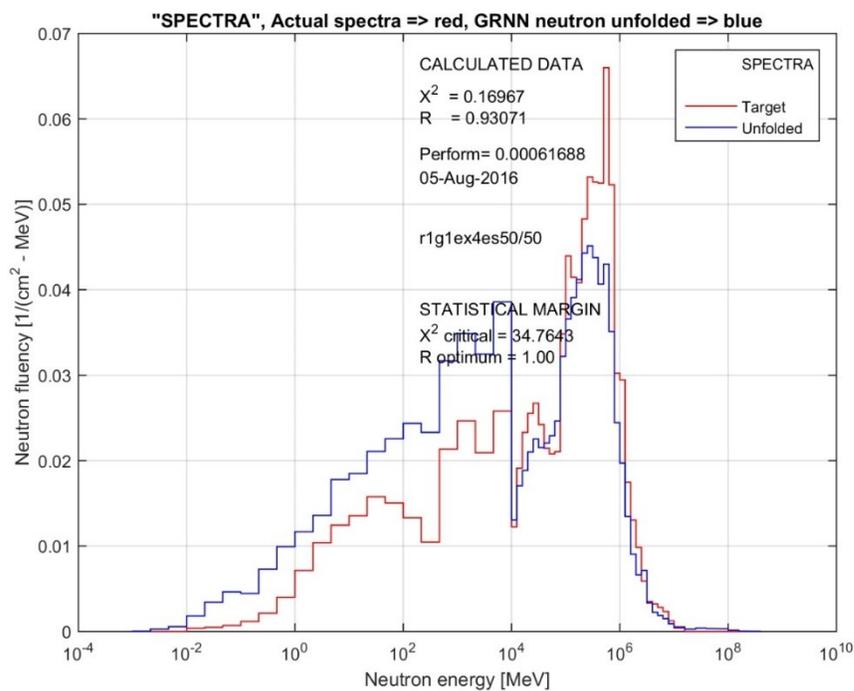


Figura 4. 25. El mejor espectro reconstruido utilizando la tasa de conteo de la esfera de cinco pulgadas del sistema del LANL.

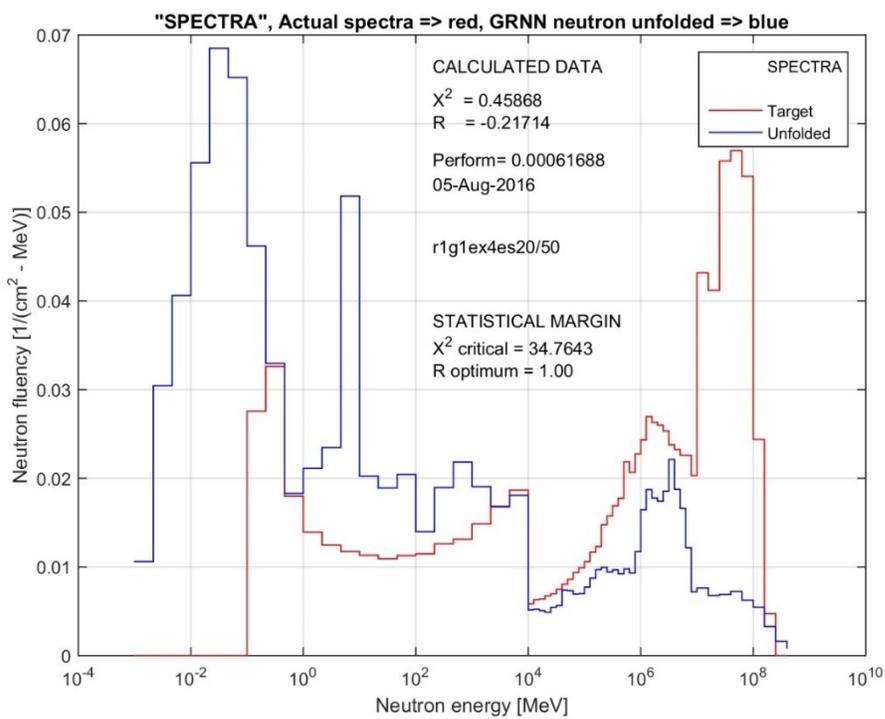


Figura 4. 26 El peor espectro reconstruido utilizando la tasa de conteo de la esfera de cinco pulgadas del sistema del LANL.

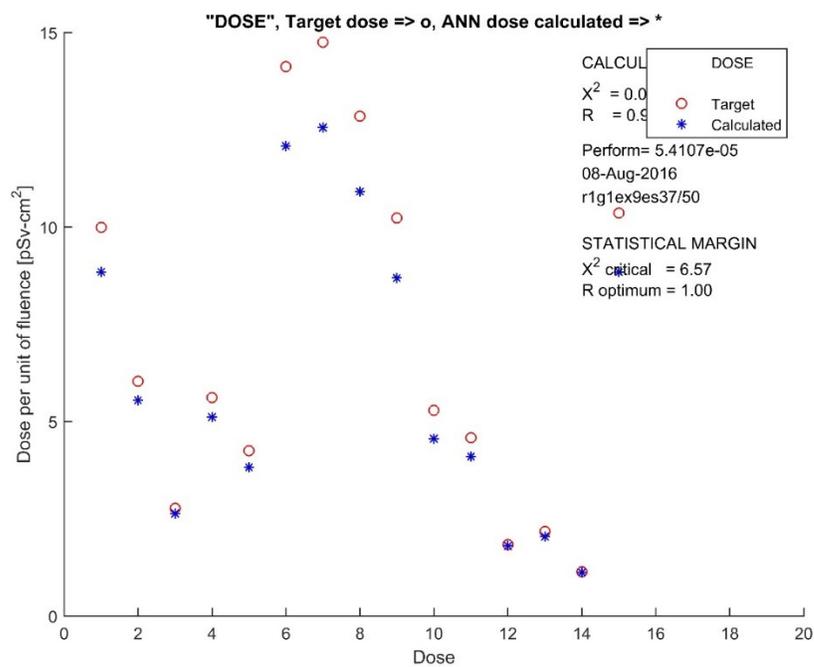


Figura 4. 27. El mejor cálculo de las dosis utilizando la tasa de conteo de cinco pulgadas del sistema de LANL.

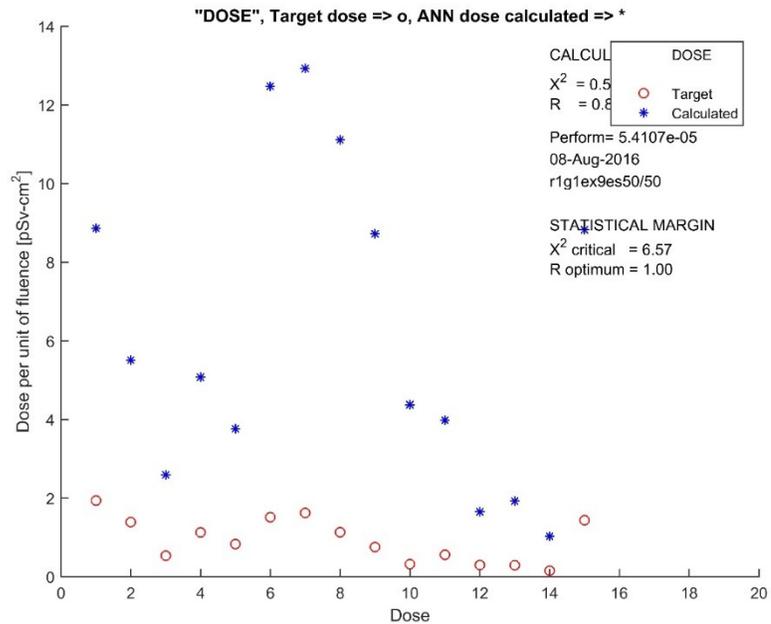


Figura 4. 28 El peor cálculo de las dosis utilizando la tasa de conteo de cinco pulgadas del sistema de LANL.

4.2.4. Resultados de ^3He de LANL con esfera de ocho pulgadas como dato de entrada.

En las figuras 4.29 y 4.30, se muestra el mejor y el peor caso de los entrenamientos para reconstruir el espectro de neutrones, mientras que en la 4.31 y 4.32 el mejor y peor caso del cálculo de las dosis, utilizando la esfera de ocho pulgadas de entrada, provenientes del SEEB, con un detector de He, del LANL en Los Alamos. Se eligió el mejor y peor caso según su correlación, el cual para el mejor caso fue de 0.954348 y el peor de 0.148824 para la reconstrucción del espectro de neutrones, mientras que el mejor y peor caso para el cálculo de las dosis es de 0.9420086 y 0.99916571 respectivamente.

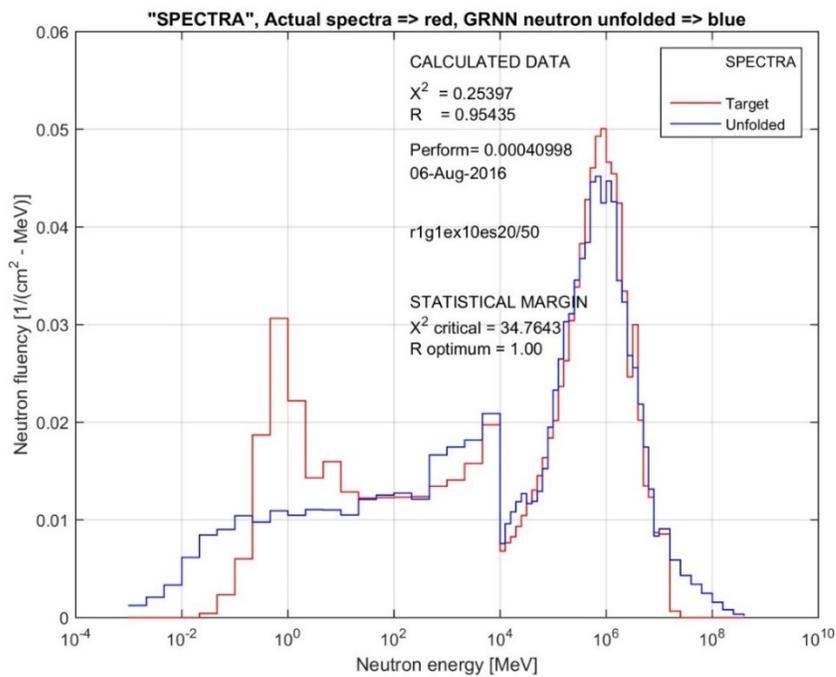


Figura 4. 29 . El mejor espectro reconstruido utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema del LANL.

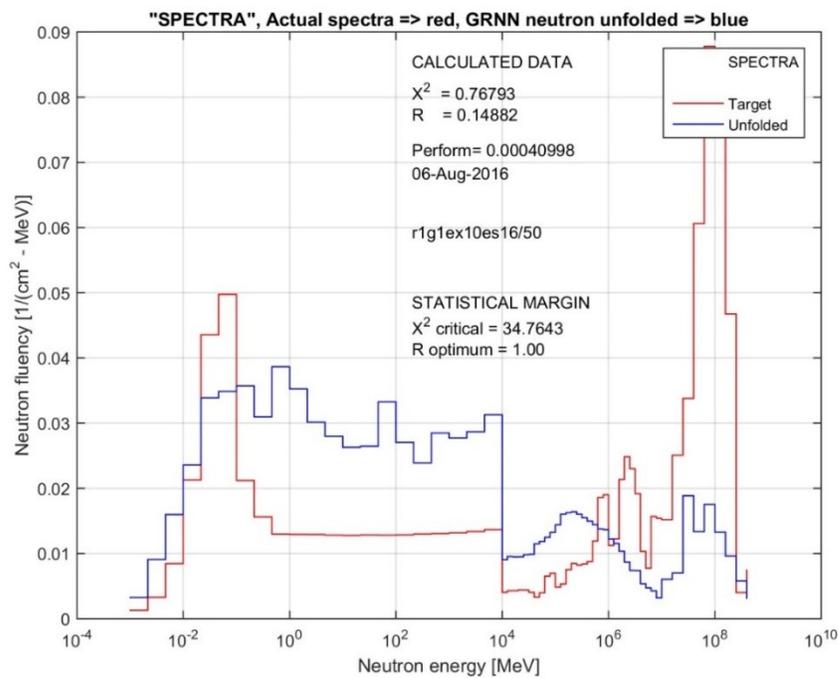


Figura 4. 30 El peor espectro reconstruido utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema del LANL.

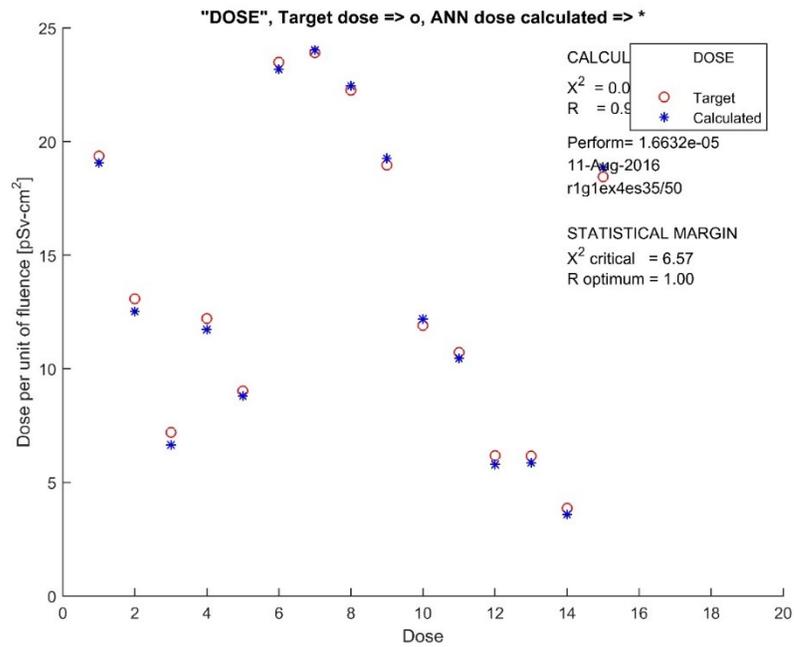


Figura 4. 31 El mejor cálculo de las dosis utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema de LANL

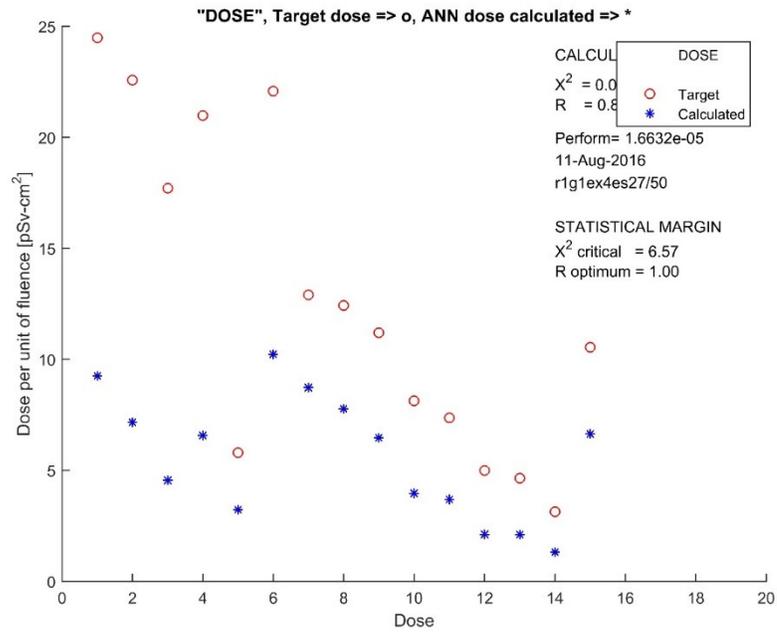


Figura 4. 32 El peor cálculo de las dosis utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema de LANL

4.3. Resultados con matriz Lil de GSF con 10, 2 y 1 esfera Bonner.

En la tabla 4.5 se observa los resultados de todos los entrenamientos de las redes para reconstruir el espectro de neutrones y en la tabla 4.6 las redes para el cálculo de las dosis, utilizando como datos de entrada, las tasas de conteo provenientes de un SEEB con un detector de Lil, de GSF, del centro de investigación para el medio ambiente y la salud en Neuherberg, Alemania.

Tabla 8 Resultados de entrenamientos con el SEEB, con un detector de Lil, de GSF.

Información	10 esferas	2 esferas	Esfera de 5 pulgadas	Esfera de 8 pulgadas
Tiempo de entrenamiento	0.0365671 s	0.06692 s	0.1032 s	0.06487 s
Desempeño de la red	0.00020159	0.000222	0.0003809	0.0005455
Promedio de CHI cuadrada	0.9306004	5.40317	110.1299	13.99342
Correlación mínima	0.5784623	0.1885246	0.12952	0.022072
Correlación máxima	0.9998048	0.9918225	0.998596	0.909931
Promedio de correlación	0.857832	0.81053696	0.603514	0.59368

Tabla 9. Resultados de entrenamientos con el SEEB, con un detector de Lil, de GSF.

Información	10 esferas	2 esferas	Esfera de 5 pulgadas	Esfera de 8 pulgadas
Tiempo de entrenamiento	0.06855	0.09907 s	0.080661 s	0.09103 s
Desempeño de la red	0.0000012	0.000003	0.00002259	0.0000507
Promedio de CHI cuadrada	0.0026264	0.0086963	0.148482	0.26422
Correlación mínima	0.956407	0.68066	0.71803	0.760506
Correlación máxima	0.99996	0.999935	0.99967	0.99968
Promedio de correlación	0.9957414	0.983921	0.964432	0.952238

4.1.1. Resultados de Lil de GSF con matriz completa de entrada.

En las figuras 4.33 y 4.34, se muestra el mejor y el peor caso de los entrenamientos para reconstruir el espectro de neutrones, mientras que en las figuras 4.35 y 4.36, se observan el mejor y peor caso del cálculo de las dosis, utilizando los 10 datos de entrada, provenientes del SEEB, con un detector de Lil, de GSF, en Neuherberg, Alemania. En las figuras. Se eligió el mejor y peor caso según su correlación, el cual para el mejor caso fue de 0.9998048 y el peor de 0.5784623 para la reconstrucción del espectro de neutrones, mientras que para el cálculo de los resultados del mejor y del peor caso del cálculo de las dosis fueron 0.99996 y 0.956407 respectivamente.

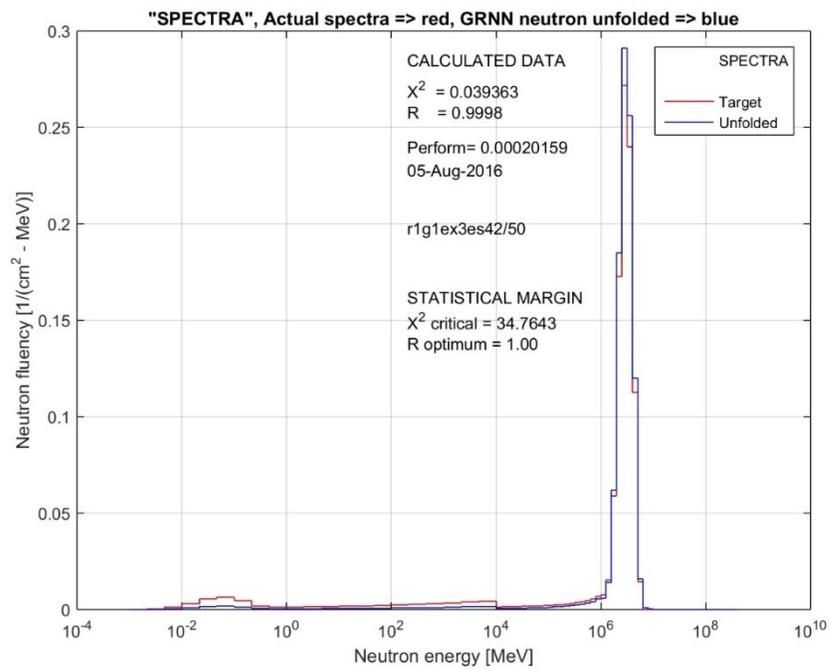


Figura 4. 33 El mejor espectro reconstruido utilizando las tasas de conteo del sistema completo de GSF.

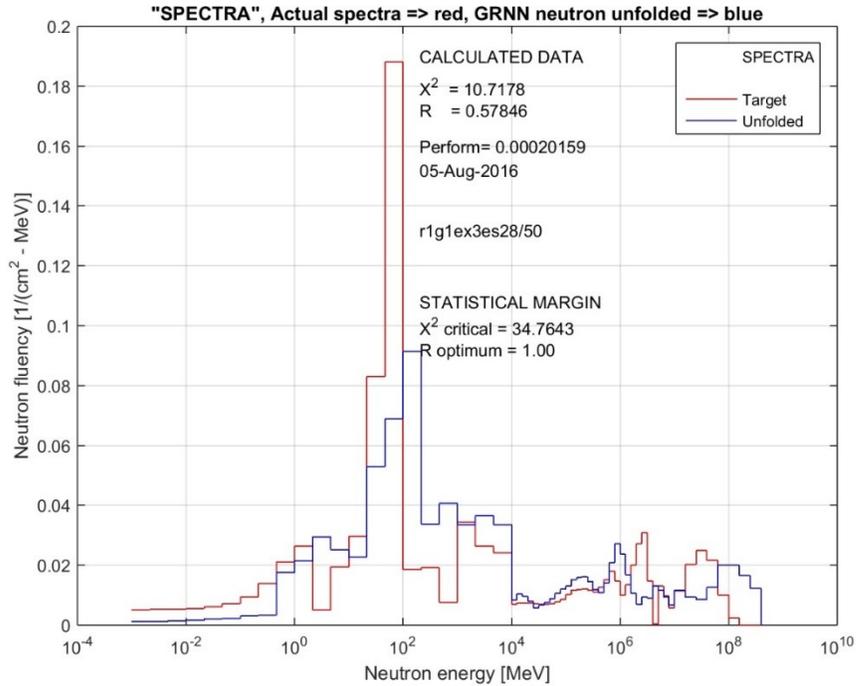


Figura 4. 34 El peor espectro reconstruido utilizando las tasas de conteo del sistema completo de GSF.

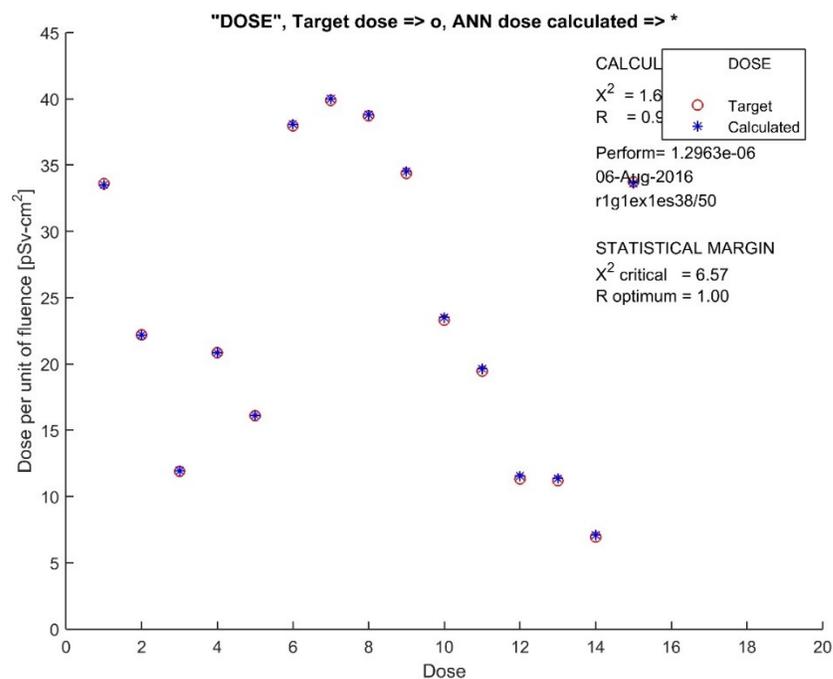


Figura 4. 35 El mejor cálculo de las dosis utilizando las tasas de conteo del sistema completo de GSF.

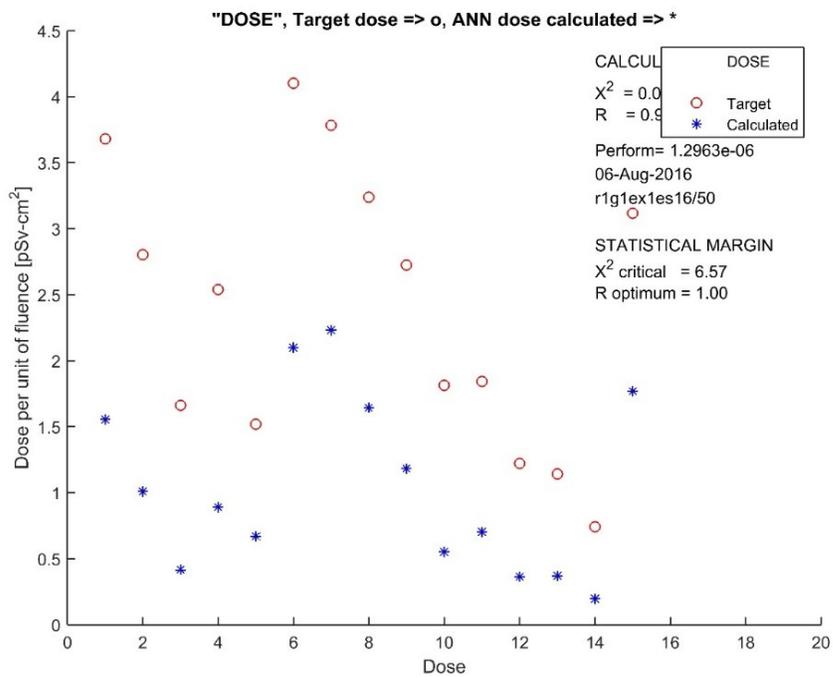


Figura 4. 36 El peor cálculo de las dosis utilizando las tasas de conteo del sistema completo de GSF.

4.1.1. Resultados de Lil de GSF con dos esferas como dato de entrada.

En las figuras 4.37 y 4.38, se muestra el mejor y el peor caso de los entrenamientos para reconstruir el espectro de neutrones, mientras que en las figuras 4.39 y 4.40, se observan el mejor y peor caso del cálculo de las dosis, utilizando dos datos de entrada, provenientes del SEEB, con un detector de Lil, de GSF, en Neuherberg, Alemania. En las figuras. Se eligió el mejor y peor caso según su correlación, el cual para el mejor caso fue de 0.9918225 y el peor de 0.1885246 para la reconstrucción del espectro de neutrones, mientras que para el cálculo de los resultados del mejor y del peor caso del cálculo de las dosis fueron 0.999935 y 0.68066 respectivamente.

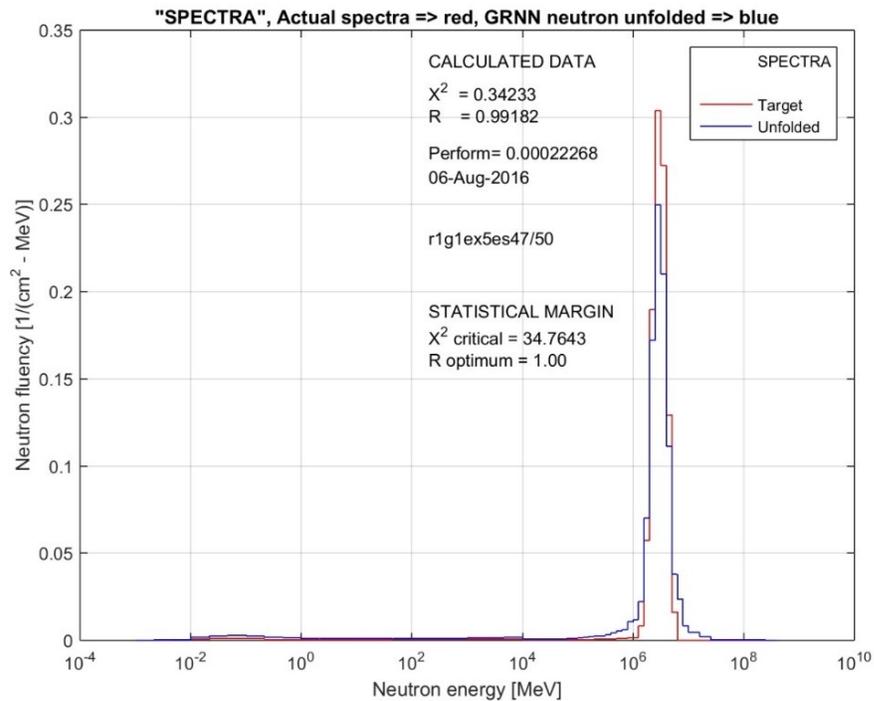


Figura 4. 37 El mejor espectro reconstruido utilizando dos tasas de conteo del sistema de GSF.

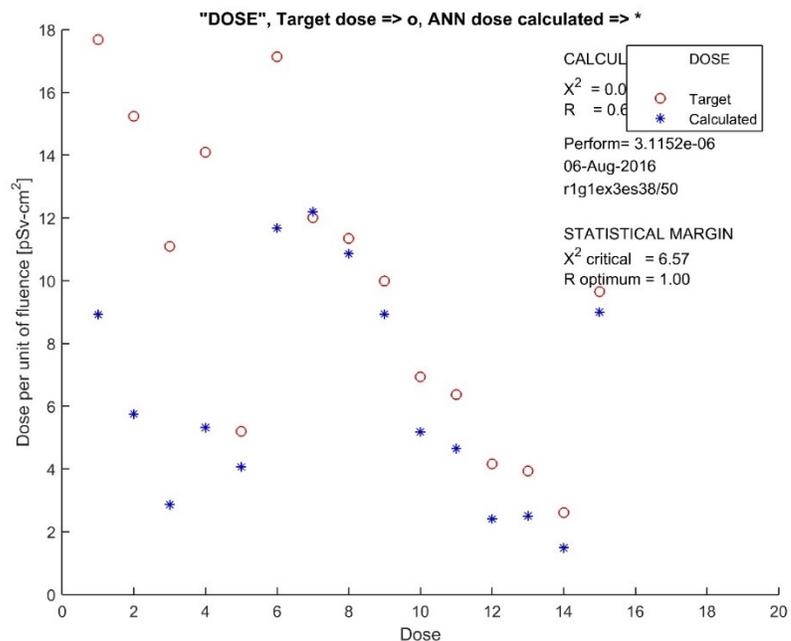


Figura 4. 40 El peor cálculo de las dosis utilizando dos tasas de conteo del sistema completo de GSF.

4.1.1. Resultados de Lil de GSF con la esfera de cinco pulgadas como dato de entrada.

En las figuras 4.41 y 4.42, se muestra el mejor y el peor caso de los entrenamientos para reconstruir el espectro de neutrones, mientras que en las figuras 4.43 y 4.44, se observan el mejor y peor caso del cálculo de las dosis, utilizando la tasa de conteo de la esfera de cinco pulgadas como único dato de entrada, provenientes del SEEB, con un detector de Lil, de GSF, en Neuherberg, Alemania. En las figuras. Se eligió el mejor y peor caso según su correlación, el cual para el mejor caso fue de 0.998596 y el peor de 0.1295 para la reconstrucción del espectro de neutrones, mientras que para el cálculo de los resultados del mejor y del peor caso del cálculo de las dosis fueron 0.99967 y 0.71803 respectivamente.

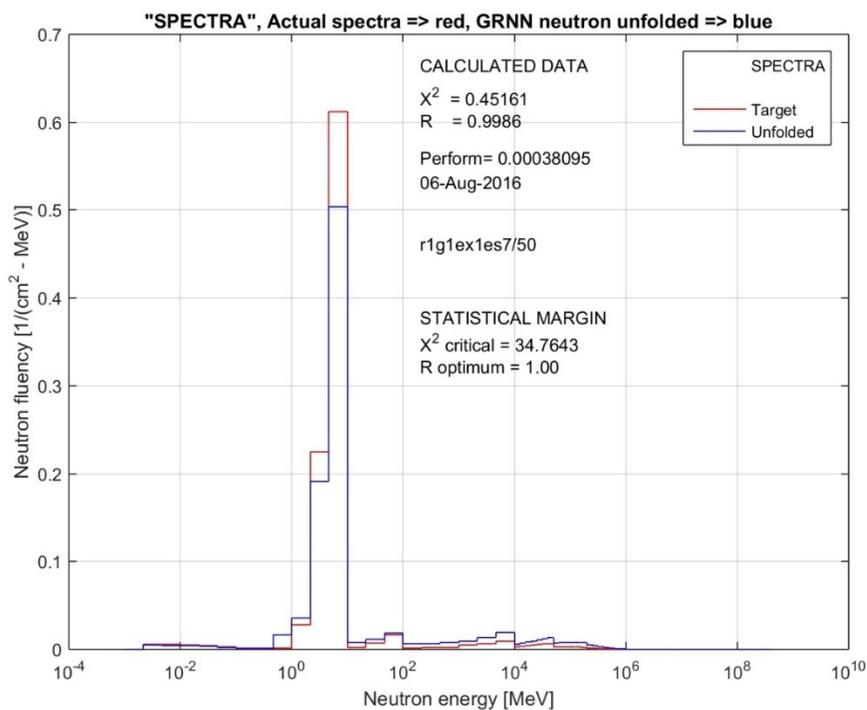


Figura 4. 41 . El mejor espectro reconstruido utilizando la tasa de conteo de la esfera de cinco pulgadas del sistema GSF.

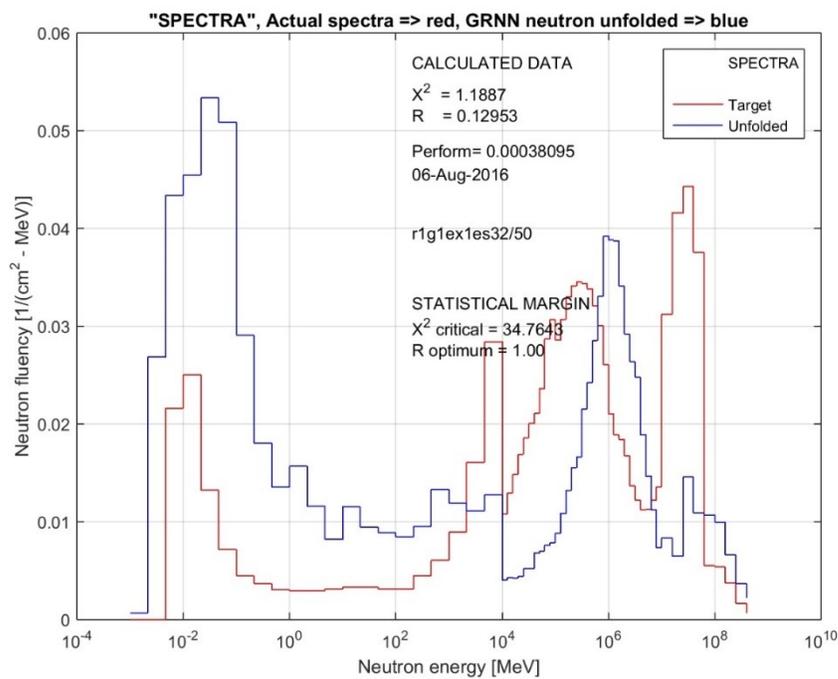


Figura 4. 42 El peor espectro reconstruido utilizando la tasa de conteo de la esfera de cinco pulgadas del sistema GSF.

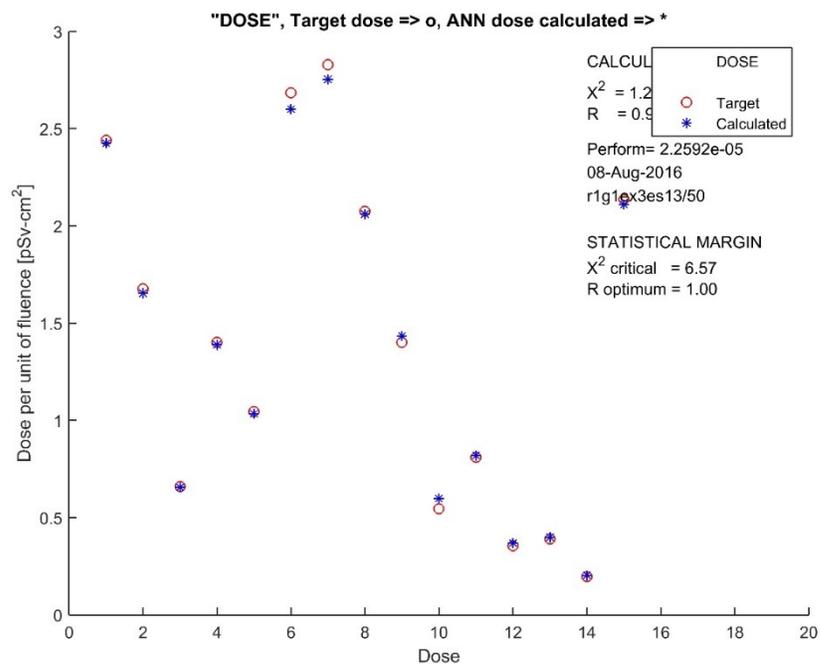


Figura 4. 43 El mejor cálculo de las dosis utilizando las tasa de conteo de la esfera de cinco pulgadas del SEEB de GSF.

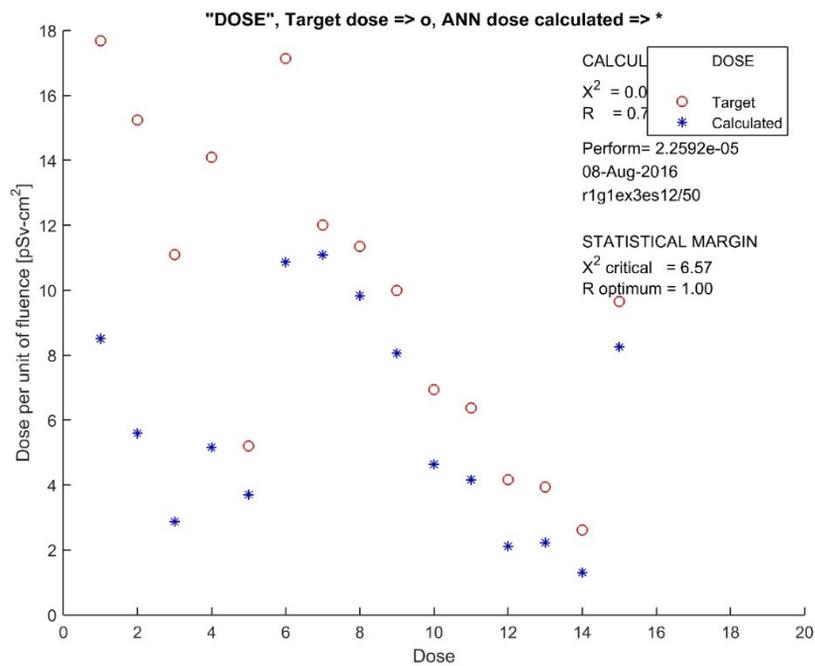


Figura 4. 44 El peor cálculo de las dosis utilizando las tasa de conteo de la esfera de cinco pulgadas del SEEB de GSF.

4.1.1. Resultados de Lil de GSF con la esfera de ocho pulgadas como dato de entrada.

En las figuras 4.45 y 4.46, se muestra el mejor y el peor caso de los entrenamientos para reconstruir el espectro de neutrones, mientras que en las figuras 4.47 y 4.48, se observan el mejor y peor caso del cálculo de las dosis, utilizando la tasa de conteo de la esfera de ocho pulgadas como unico dato de entrada, provenientes del SEEB, con un detector de Lil, de GSF, en Neuherberg, Alemania. En las figuras. Se eligió el mejor y peor caso según su correlación, el cual para el mejor caso fue de 0.909931 y el peor de 0.022072 para la reconstrucción del espectro de neutrones, mientras que para el cálculo de los resultados del mejor y del peor caso del cálculo de las dosis fueron 0.99968 y 0.760506 respectivamente.

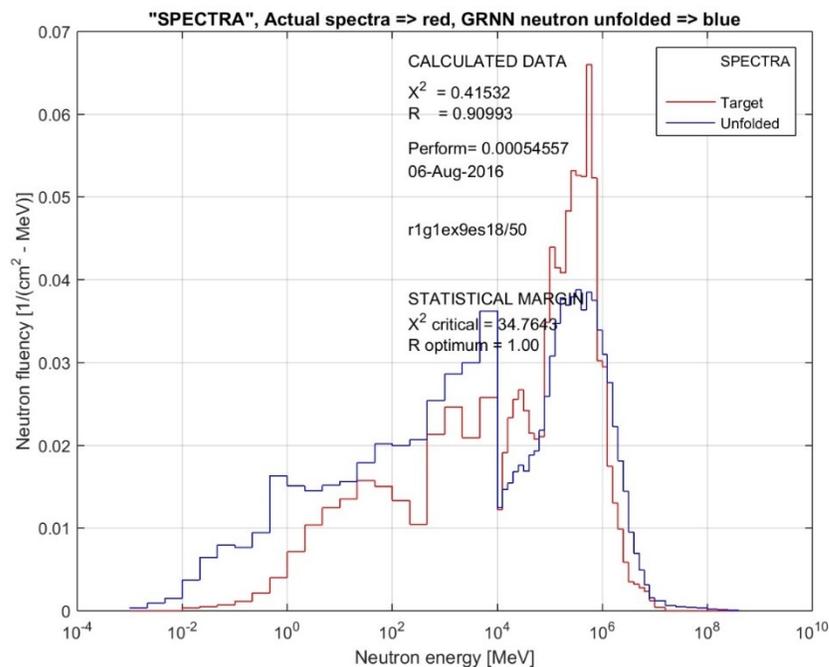


Figura 4. 45 El mejor espectro reconstruido utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema GSF.

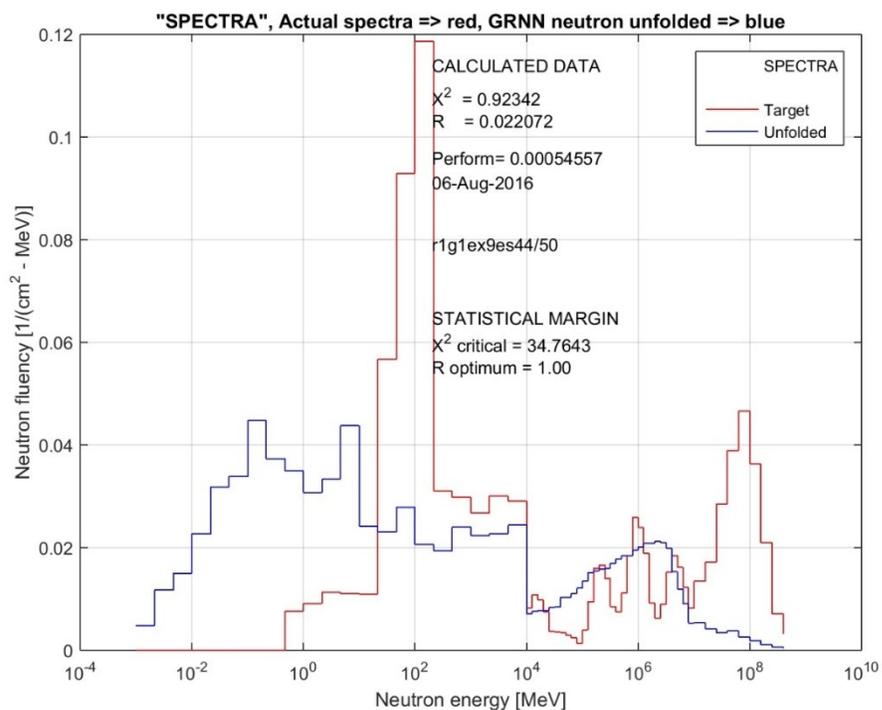


Figura 4. 46 El peor espectro reconstruido utilizando la tasa de conteo de la esfera de ocho pulgadas del sistema GSF.

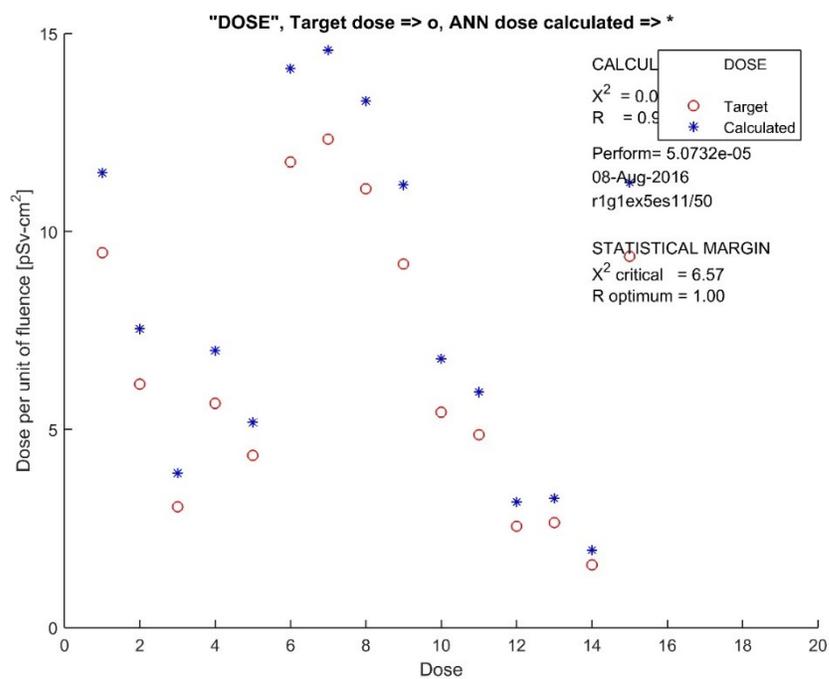


Figura 4. 47 El mejor cálculo de las dosis utilizando la tasa de conteo de la esfera de ocho pulgadas del SEEB de GSF.

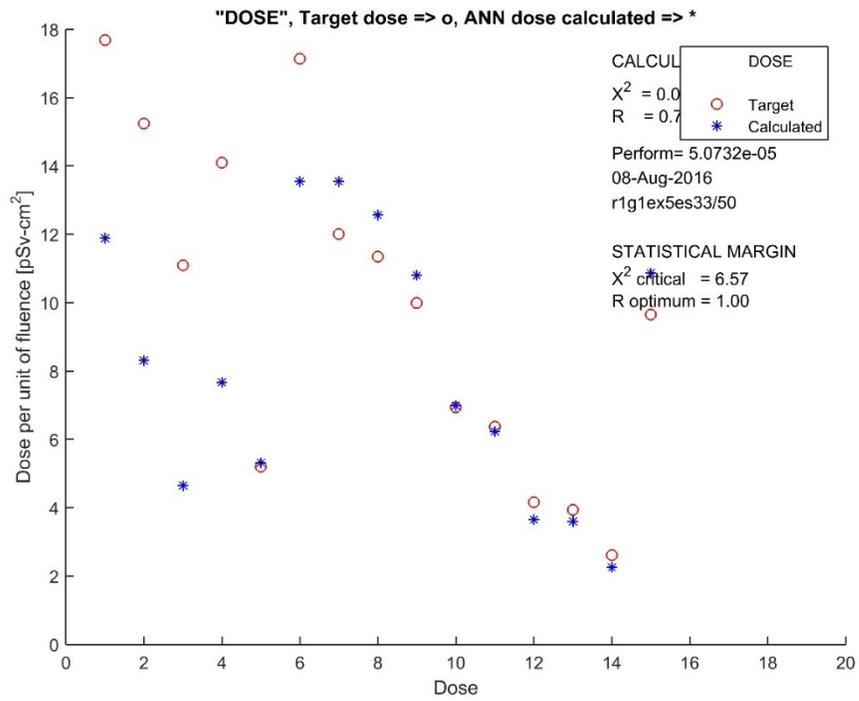


Figura 4. 48 El peor cálculo de las dosis utilizando la tasa de conteo de la esfera de ocho pulgadas del SEEB de GSF

CAPITULO 4

CONCLUSIONES

Las redes neuronales artificiales de regresión generalizada, son una herramienta excelente para resolver el problema de reconstruir el espectro de neutrones y el cálculo de sus dosis. A comparación de otros métodos tradicionales, esta herramienta tiene una gran variedad de ventajas, como el tiempo en que la red entrega el espectro reconstruido, y/o el cálculo de sus dosis, que las RNA no requieren información a priori del espectro, y otros. A comparación de herramientas como la de redes neuronales artificiales de propagación inversa, la cual, ya ha sido utilizada en trabajos anteriores, y se obtuvieron buenos resultados, pero no libre de problemas, como le hecho de tener distintas variables que el usuario puede y otras que no puede controlar, las redes neuronales de regresión generalizada, ofrecen beneficios como, reducir las variables que el usuario pueda controlar a una sola, siendo la constante de generalización. Al tener una única variable, las probabilidades de que variar el desempeño del a red se reducen, además se minimiza el tiempo de entrenamiento a una pequeña porción.

En los entrenamientos, se utilizaron como dato de entrada, las tasas de conteo provenientes de tres laboratorios, con 15 esferas para PTB, el cual usa un detector de ^3He , 11 esferas de LANL que tiene un detector de ^3He , y 10 esferas de GSF con un detector de ^6Li . En el caso de los entrenamientos, tanto para reconstruir el espectro de neutrones como para el cálculo de sus dosis, utilizando todas las tasas de conteo de las matrices, los resultados fueron excelentes, y a pesar de hacer distintos entrenamientos, casi invariablemente, eran buenos resultados.

En el caso de reducir las entradas a dos esferas, para la reconstrucción del espectro de neutrones, se mostró mayor dificultad en arrojar buenos resultados, pero al entrenar varias veces para poder elegir la mejor red, se encontró redes con buenos resultados. Para el caso de dos entradas para calcular las dosis, prácticamente los resultados fueron como con la matriz completa, al mantener buena calidad en los resultados, a pesar de entrenar la red en varias ocasiones.

En el caso de reducir a una única tasa de conteo como dato de entrada, para la reconstrucción del espectro de neutrones, se mostraron malos resultados, la mayoría de los resultados, en la correlación mínima, salían negativos, y a pesar de entrenar entre 10 a 30 veces por caso, no se obtuvieron resultados favorables. Mientras que en el caso del cálculo de las dosis, aunque se redujo el desempeño de la red, después de entrenar la red entre 10 a 30 veces, se encontraron resultados no excelentes, pero si manteniendo buena eficiencia la mayoría.

Por lo tanto, al utilizar un único dato de entrada, solo será posible para calcular las dosis. Utilizando dos datos de entrada, para ambos casos es posible utilizar las redes neuronales artificiales, solo se debe tener mucho cuidado en elegir la red que se utilizara para reconstruir el espectro de neutrones, y para el caso donde se utilizan la totalidad de las esferas, casi invariablemente, los resultados serán buenos.

Referencias

- A. Antonov, A. (2011). From artificial intelligence to human superintelligence. *international journal of computer information systems*, vol. 2, No. 6.
- Aldrich H., & Martinez, M. (2001). Many are called, but few are chosen: An evolutionary perspective for the study of entrepreneurship. *Entrepreneurship Theory and practice*, 41-56.
- Arbib, M. (2003). *The handbook of brain theory and neural networks*.
- Bakali, M. (2001). *tesis doctoral "Espectrometría neutrónica en las centrales nucleares mediante un sistema de esferas Bonner"*. Barcelona, España.
- Barros, S., Gallego, E., Lorente, A., Gonçalves, I., Vaz, p., Vega Carrillo, H. R., & Zankl, M. (2014). Neutron spectra and dosimetric assessment around a neutron hoxitzer container. *Progress in nuclear science and technology* 4, 757-761.
- Bedogni, R., Ferrari, P., Gualdrini, G., & Esposito, A. (2010). Design and experimental validation of a Bonner Sphere Spectrometer based on Dysprosium activation foils. *Radiation measurements* 45, 1201-1204.
- Braga, C., & Dias, M. (2002). Application of neural networks for unfolding neutron spectra measured by means of Bonner Spheres. *Nuclear instruments and methods in physics research A* 476, 252-255.
- Bramblett, R., Ewing, R., & Bonner, T. (1960). A new type of neutron spectrometer. *Nuclear Instruments and Methods* 9, 1-12.

- Cadena, J., Cadena, J., & Perez Londoño, S. (2008). Probabilistics neural networks application in the diagnosis of transformer incipient faults. *Scientia et technica año XIV (39)*.
- Carri, V. (2006). Ar. *Radiatio*, 251-259.
- Da Silva, G. (2010). Identificación de daño en materiales magnetoelásticos utilizando redes neuronales.
- Diaz, C. (2002). *La creación de empresas: Revisión, Historia de teorías y Escuelas*. Ediciones la coria.
- Drucker, P. F. (1997). *Innovation and entrepreneurship: practice and principles*. New York: Harper and Row Publishers.
- Falavigna, G. (2012). Financial ratings with scarce information: a neural network approach. *Expert System Applications*, 1784-1792.
- Fehrenbacher, G., Schütz, R., Hanh, K., Sprunck, M., Biersack, J., & Wahl, W. (1999). Proposal of a new method for neutron dosimetry based on spectral information obtained by application of artificial neural networks. *Radiation Protection Dosimetry* 83(4), 293-301.
- Fritzsche P. . (2008). Tools in artificial intelligence. *InTech*.
- Gutiérrez Rosas, P., Vázquez López, J., Hernández Ripalda, M., & Ríos Lira, A. (2013). Aplicación de la red neuronal probabilística para la clasificación de productor conforme a sus especificaciones. *Innovation in engineering technology and education for competitiveness and prosperity*.
- Gupta, N., & Pratap Narwaria, R. (2014). Design low pass FIR filter using generalized regression neural network. *International journal of signal processing and pattern recognition*, 75-84.
- Gutiérrez Tapia, C., & Flores Llamas, H. (2010). *Problemas inversos, métodos de regularización y la función de distribución de energías de electrones*. Contr. del ININ.
- Hannan, S., Manza, R., & Ramteke, R. (2010). Generalized regression neural network and radial basis function for heart disease diagnosis. *International journal of computer applications (7)*.
- Harley, J. (1999). The calibration of neutron instruments and dosimeter at intermediate energies. *Nuc. Instruments Methods* 148, 511-520.
- Haugeland, J. (1997). Mind design philosophy psychology artificial intelligence. *The MIT Press*.
- Haykin, S. (2001). *Neural networks, a comprehensive foundation*. Hamilton, Ontario, Canada: Pearson Education.
- Heibronn, L. (2015). Neutron properties and definitions. *NASA summer schools sessions on radiation physics*.
- ICRU. (2001). Neutron field characterization, International Commission on Radiation Units and Measurements Report. 66. *ICRU 1*, 27-33.

- INEGI. (2016). Estadísticas detalladas sobre las micro, pequeñas y medianas empresas del país. *Boletín de prensa*.
- kardan, M., Setaycshi, S., Koohu-Fayegh, R., & Ghiassi-Nejad, M. (2003). Neutron spectra unfolding in Bonner spheres spectrometry using neural networks. *Radiat. Prot. Dosim.*, 2014.
- Knoll, G. (1999). Radiation detection and measurement. *John Wiley & Sons*, 3a edition.
- Korany, M. (2012). Application of artificial neural networks for response surface modelling in HPLC method development. *Adv. Res.*, 53-63.
- Lacoste, V., Gressier, V., Pochat, J., Fernandez, F., Bakali, M., & Boassoule, T. (2004). Characterization of bonner spheres systems at monoenergetic and thermal neutron fields. *Radiat. Prot. Dosim.*
- Lee, S., Ryu, J., Won, J., & Park, H. (2004). Determination and application of the weights for landslide susceptibility mapping using an artificial neural network. *Engineering geology* 71, 289-302.
- Leshno, M., Lin, V., Pinkus, A., & Schocken, S. (1993). Multilayer Feedforward Network With a Nonpolynomial Activation Function Can Approximate Any Function. *Neural networks* 6, 861-867.
- Lindemann, L., & Zech, G. (1995). Unfolding by weighting Monte Carlo events. *Nucl. Instrum. Meth. Phys.* 38, 185-191.
- Ljung, L. (1999). *System Identification: Theory for the User*. Prentice Hall.
- Luger, G., & Stubblefield, W. (1998). Artificial Intelligence, structures and strategies for complex solving problems. *Addison Wesley*.
- Martinez Blanco, M. (2006). *Espectrometría de neutrones y cálculo simultáneo de dosis equivalentes empleando la metodología de diseño robusto de redes neuronales*. Zacatecas: Tesis de maestría.
- Martinez Blanco, M., Ornelas Vargas, G., Castañeda Miranda, C., Solís Sánchez, L., Castañeda Miranda, R., Vega Carrillo, H., . . . Ortiz Rodríguez, J. (2016). A neutron spectrum unfolding code based on generalized regression artificial neural networks. *Applied radiation and isotopes*.
- Matijevic, G. (2008). *Spectra classification with artificial neural networks*.
- Matijevic, G. (2008). Spectra Classification with artificial neural networks.
- McDonald, J., Siebert, B., & Alberts, W. (2001). Neutron spectrometry for radiation protection purposes. *Nuclear Instruments and Methods in Physics Research A* 476, 347-352.
- Mukherjee, B. (2002). A high-resolution neutron spectra unfolding method using the Genetic Algorithm technique. *Nucl. Instrum. Meth. Phys. Res. A* 476, 247-251.
- Negnevitsky, M. (2005). Artificial intelligence, a guide to intelligent systems. *Addison Wesley*.

- Oirtiz Rodriguez, J. M. (2011). *Tesis doctoral "Inteligencia artificial: Aplicaciones a la espectrometria y dosimetria neutronicas"*. Córdoba: España.
- Ortiz Rodriguez, J. M., Reyes Alfaro, A., Reyes Haro, A., Cervantes Viramontes, J. M., & Vega Carrillo, H. R. (2014). A neutron spectrum unfolding computer code based on artificial neural networks. *Radiation physics and chemistry* 95, 428-431.
- Ortiz Rodriguez, J., Martinez Blanco, M., & Vega Carrillo, H. (2011). Evolutionary artificial neural networks un neutron spectrometry. In *Artificial neural networks application* (pp. 499-524). INTECH.
- Ortiz Rodriguez, J., Martínez Blanco, M., Castañeda Miranad, R., Vega Carrillo, H., & Solís Sanchez, L. (2015). A neutron spectrum unfolding code based on generalized regression artificial neural networks. *miscellaneous in international symposium on solid state dosimetry*.
- Ortiz Rodriguez, J., Martnez Blanco, M., Cervantes Viramontes, J., & Vega Carrillo, H. (2013). Robust design of artificial neural networks methodology in neutron spectrometry. In K. Suzuki, *artificial neural networks - architecture and applications* (pp. 83-112).
- Ortiz Rodriguez, J., Reyes Alfaro, A., Reyes Haro, A., Cervantes Viramontes, J., & Vega Carrillo, H. (2014). A neutron spectrum unfolding computer code based on artificial neural networks. *Radiation physics and chemistry* 95, 428-431.
- Rasskin Gutman, D. (2009). Chess metaphors, artificial intelligence and the human brain. *The MIT press*.
- Reginatto, M. (2009). What can we learn about the spectrum of high energy stray neutron fields from Bonner sphere measurements? *Radiation Measurements* 44, 692-699.
- Reginatto, M., Goldhagen, P., & Neumann, S. (2002). Spectrum unfolding sensitivity analysis and propagation of uncertainties with the maximum entropy deconvolution code MAXED. *Nucl. Instrum. Meth. Phys. Res. A* 476, 242-246.
- Reyes Alfaro, A., Ortiz Rodriguez, J., Reyes Haro, A., Castañeda Miranda, R., Solis Sanchez, L., & Vega Carrillo, H. (2014). Optimizacion de redes neuronales artificiales para la reconstruccion del espectro de neutrones y sus dosis equivalentes. *publications in IAEA*.
- Routti, J., & Sandberg, J. (1980). General purpose unfolding program LOUHI78 with linear and non-linear regularizations. *Comp. Phys. Comm.* 21, 119-144.
- Russel, S., & Norvin, P. (1995). Artificial Intelligence, a moder approach. *Prentice Hall*.
- Shani, G. (2001). Radiation dosimetry, instrumentation and methods. *CRC Press*.
- sharma, R. (2015). *11 obsessions of remarkable entrepreneurs*.
- Specht, D., & Shapiro, P. (1990). Training speed comparison of probabilistic neural networks with backpropagation networks. *Proc. Int. Neural Networks Conf. (1)*, 440-443.

- Sridhar Sriram, P. (2005). *Developing neural network applications using labview*. missouri-columbia: thesis of master of science.
- Thomas, D. (2002). Bonner sphere spectrometers, a critical review. *nucl. instrum. methods phys. Res. Sect. A* 476, 12-20.
- Thomas, J. D. (2004). Neutron spectrometry for radiation protection. *Radiat. Prot. Dosim.*, 110.
- Vega Carrillo, H., Hernandez Davila, V., Manzanares Acuña, E., Iñiguez de la Torre, M., Barquero , R., Mercado Sanchez, G., . . . Ortiz Rodriguez, J. (2005). Neutron spectrometry using artificial neural networks. *radiat. measurement*.
- Vega Carrillo, H., Hernandez Davila, V., Manzanares Acuña, E., Mercado Sanchez , G., Iñiguez de la Torre, M., Barquero , R., . . . Ortiz Rodriguez , J. (2006). Neutron spectrometry using artificial neural networks. *Radiation Measurements* , 41, 425-431.
- Vega Carrillo, H., Hernández Davila, V., Manzanares Acuña, E., Mercado, G., Gallego, E., Lorente, A., . . . Robles Rodríguez, J. (2006). artificial neural networks in neutron dosimetry. *Radiation Protection Dosimetry Vol. 118*, 251-259.
- Vega Carrillo, H., Wehring, B., & Hertel, N. (1999). Response matrix for a multisphere spectrometer using a 6LiF thermoluminescence dosimeter. *Radiation protection dosimetry* 81, 133-139.
- White, J., & White, A. (2011). The neutron - The curie Family's legacy. *Aust. J. Chem.*, 855-863.
- Yu, W. (2009). Recent advances in intelligence control systems. *Springer-Verlag*.