



Análisis, diseño e implementación de tecnología basada en redes neuronales de regresión generalizada para la solución de problemas inversos, aplicada en espectrometría y dosimetría neutrónica

Derechos de autor

Todos los derechos reservados

Ma. del Rosario Martínez Blanco

Prohibida su reproducción total o parcial,
sin consentimiento expreso de la autora

México MMXVII



Universidad Autónoma de Zacatecas

Unidad Académica de Ingeniería Eléctrica

Análisis, diseño e implementación de tecnología basada en redes neuronales de regresión generalizada para la solución de problemas inversos, aplicada en espectrometría y dosimetría neutrónica

Tesis

Que en cumplimiento parcial de los requisitos para obtener el grado de
DOCTOR EN INGENIERÍA Y TECNOLOGÍA APLICADA

Presenta

Ma. del Rosario Martínez Blanco

Directores de tesis

Dr. José Manuel Ortiz Rodríguez (UAZ - México)
Dr. Héctor René Vega Carrillo (UAZ - México)
Dr. Luis Octavio Solís Sánchez (UAZ - México)
Dr. Roberto Méndez Villafañe (CIEMAT - España)

Zacatecas, Zac., México – Febrero de 2017



Exp. Tit. 01/2017

**DRA. SAMNTA DECIRE BERNAL AYALA
COORDINADORA DEL DEPARTAMENTO
ESCOLAR CENTRAL DE LA UAZ
PRESENTE.**

Nos permitimos informarle que, **Martínez Blanco Ma. Del Rosario**, alumna egresada del Posgrado de Doctorado en Ingeniería y Tecnología Aplicada con número de matrícula 97501856, ha solicitado presentar su examen profesional con la modalidad de titulación por Tesis, **cual lleva por nombre, “Análisis, diseño e implementación de tecnología basada en redes neuronales de regresión generalizada para la solución de problemas inversos, aplicada a la espectrometría y dosimetría neutrónica”**. Para optar el título de Doctora en Ingeniería y Tecnología Aplicada.

Lo anterior me permito hacerlo de su conocimiento para los trámites a que haya lugar y aprovecho la ocasión para quedar a sus órdenes.

Atentamente

Zacatecas, Zac., a 10 de febrero de 2017

DR. JORGE DE LA TORRE Y RAMOS
DIRECTOR DE LA
UNIDAD ACADÉMICA DE INGENIERÍA ELÉCTRICA
DOCTORADO EN INGENIERÍA
Y TECNOLOGÍA APLICADA UAZ



“FRANCISCO GARCÍA SALINAS”
Unidad Académica de Ingeniería Eléctrica

Dra. Samanta Deciré Bernal Ayala.
Departamento de Servicios Escolares.
Presente.

El suscrito **Dr. José Manuel Ortiz Rodríguez** docente de la Maestría en Ingeniería y Tecnología Aplicada, dependiente de la Universidad Autónoma de Zacatecas:

DICTAMINA

Que después de haber revisado la Tesis titulada **“Análisis, diseño e implementación de tecnología basada en redes neuronales de regresión generalizada para la solución de problemas inversos, aplicada a la espectrometría y dosimetría neutrónica”** Presentada por la **C. Ma. Del Rosario Martínez Blanco**, egresada de este programa educativo con matrícula **97501856**, cumple con todos los requisitos que el reglamento de titulación de los posgrados exige para este tipo de trabajos, por lo que el mencionado egresado puede pasar a reproducirlo para presentar su Examen Profesional.

Se extiende la presente a solicitud del interesado, para los fines legales que a el mismo convenga, en la ciudad de Zacatecas, Zac. A los 10 días del mes de febrero del año dos mil diecisiete.

Asesor de Tesis
Dr. José Manuel Ortiz Rodríguez



Análisis, diseño e implementación de tecnología basada en redes neuronales de regresión generalizada para la solución de problemas inversos, aplicada en espectrometría y dosimetría neutrónica

Aprobada por el jurado:

Dr. José Manuel Ortiz Rodríguez

Dr. Héctor René Vega Carrillo

Dr. Roberto Méndez Villafañe

Dr. Luis Octavio Solís Sánchez

Dr. Alfredo Lara Herrera

Dedicatoria

A mis tres grandes amores:

Manuel, Richy, Sofy

Por ser los motores en mi vida

A mi incomparable familia:

Carlos (papi), Silvia (mami), Chivis, Carlitos, Rossy

Por el apoyo y ejemplo que se vuelven mi gran motivación

Agradecimientos

Este trabajo fue parcialmente apoyado por:

-) Fondo Sectorial de Investigación para la Educación de CONACyT bajo el convenio 241771, con número de becario 23386.
-) Fondos Mixtos SEP-CONACYT – Gobierno del Estado de Zacatecas bajo el convenio ZAC-C03-2015-26357-4.
-) El programa para el Desarrollo de la Industria del Software y la Innovación (PROSOFT) 2015, bajo el convenio 201513723.
-) El Centro de Investigación e Innovación Tecnológica Industrial (CIITI) y el Laboratorio de Innovación y Desarrollo Tecnológico en Inteligencia Artificial (LIDTIA) con sede en la Universidad Autónoma de Zacatecas.

Resumen

El objetivo de este proyecto de investigación fue analizar, diseñar e implementar una herramienta basada en redes neurales de regresión generalizada (GRNN) para predecir el espectro de neutrones y/o cálculo de 15 cantidades dosimétricas usando las tasas de conteo procedentes de un sistema espectrométrico de esferas Bonner como la única información. En las etapas de entrenamiento y prueba, se utilizó un conjunto de datos de 251 espectros de neutrones, tomados de la compilación de la Agencia Internacional de Energía Atómica. Tomando el 80 por ciento de datos para entrenamiento y cincuenta espectros analizados en la etapa de prueba. La herramienta científico-tecnológica diseñada a partir de la tecnología redes neuronales de regresión generalizada capaz de resolver el problema de espectrometría de neutrones con alto rendimiento y capacidad de generalización, fue diseñada bajo el entorno MATLAB. Esta herramienta computacional automatiza el pre-procesamiento de información, las etapas de entrenamiento y prueba, el análisis estadístico y el post-procesamiento de la información. Se comparó el rendimiento de las redes neuronales de propagación hacia delante entrenadas por medio del algoritmo de propagación inversa (RNAPAPI) y GRNN en la solución del problema de espectrometría de neutrones, observando que las GRNN tienen un desempeño mejor que el RNAPAPI.

Palabras clave: Inteligencia artificial, solución de problemas inversos, regresión generalizada, espectrometría de neutrones.

Abstract

The aim of this research was to analyze, design and implement a generalized regression neural network to predict the neutron spectrum and to calculate 15 dosimetric quantities using the count rates, coming from a Bonner spheres spectrometric (BSS) system as the only entrance information. A dataset of 251 neutron spectra, compiled from the International Atomic Energy Agency, was used at training and test stages. 80 percent of the whole data set was used for training the neural networks and remaining 20 percent at test stage. The scientific-technological tool designed from the generalized regression neural networks technology capable of solving the problem of neutron spectrometry with high performance and generalization capacity was designed under the MATLAB environment. This computational tool automates the pre-processing of information, the stages of training and testing, statistical analysis and post-processing of information. We compared the performance of feed forward propagation neural networks trained by the back propagation algorithm and generalized regression neural networks in the solution of the neutron spectrometry problem, noting that GRNNs perform better than back propagación neural networks.

Keywords: Artificial intelligence, inverse problem solving, generalized regression, neutron spectrometry.

Índice general

DEDICATORIA.....	VI
AGRADECIMIENTOS.....	VII
RESUMEN.....	VIII
ABSTRACT.....	IX
INTRODUCCIÓN.....	1
JUSTIFICACIÓN.....	9
PREGUNTA CIENTÍFICA.....	13
HIPÓTESIS.....	13
OBJETIVO GENERAL.....	14
<i>Objetivos particulares</i>	14
REVISIÓN DE LITERATURA.....	16
2.1. INTELIGENCIA ARTIFICIAL Y CONEXIONISMO.....	16
2.2. APRENDIZAJE DE MÁQUINAS Y CONEXIONISMO.....	16
2.3. REDES NEURONALES ESTADÍSTICAS.....	27
2.3.1. <i>Redes neuronales de función de base radial</i>	27
2.3.2. <i>Redes neuronales probabilísticas</i>	33
2.3.3. <i>Redes neuronales de regresión generalizada</i>	35
2.4. ESPECTROMETRÍA DE NEUTRONES POR MEDIO DE REDES NEURONALES DE REGRESIÓN GENERALIZADA.....	40
2.4.1. <i>Los neutrones</i>	40
2.4.1.1. Introducción.....	40
2.4.1.2. El descubrimiento del neutrón.....	42
2.4.1.3. Clasificación y propiedades de los neutrones.....	43
2.4.1.4. Producción de neutrones.....	44
2.4.1.5. Interacción de los neutrones con la materia y el tejido.....	45
2.5. DOSIMETRÍA DE CAMPOS NEUTRÓNICOS.....	48
2.5.1. <i>Protección radiológica</i>	48
2.5.2. <i>Espectrometría y dosimetría de neutrones</i>	49
2.5.3. <i>Evolución de la espectrometría neutrónica</i>	50
2.5.4. <i>Espectrometría de neutrones a partir del SEEB</i>	51
2.6. CÓDIGOS Y TÉCNICAS DE DECONVOLUCIÓN.....	54
2.6.1. <i>El problema de la reconstrucción</i>	55
2.6.2. <i>Métodos y códigos utilizados para la deconvolución</i>	56

MATERIALES Y MÉTODOS	59
3.1. PRE-PROCESAMIENTO DE LA INFORMACIÓN DE DATOS DE ENTRENAMIENTO	60
3.2. DEFINICIÓN DEL VALOR CRÍTICO DEL <i>KERNEL DE PROPAGACIÓN CONSTANTE</i> DE RNARG	68
3.3. ENTRENAMIENTO DE LA RNRG	71
3.3.1. <i>Reconstrucción del espectro y cálculo de cantidades dosimétricas</i>	78
3.3.2. <i>Aplicación de la herramienta diseñada en experimentos reales</i>	80
3.4. COMPARANDO RESULTADOS OBTENIDOS FRENTE A MÉTODOS CLÁSICOS.....	83
RESULTADOS Y DISCUSIÓN	85
4.1. CAPÍTULOS DE LIBRO	86
4.2. ARTÍCULOS CON ÍNDICES DE IMPACTO	87
4.3. PARTICIPACIÓN EN CONGRESOS	89
4.3.1. <i>Año 2015</i>	89
4.3.2. <i>Año 2016</i>	89
4.4. FORMACIÓN DE CAPITAL HUMANO.....	92
4.4.1. <i>Co-asesoría en tesis de licenciatura</i>	92
4.4.1.1. Optimización de la arquitectura de una red neuronal en espectrometría de neutrones para reducir el número de esferas Bonner.	92
4.4.1.2. Entrenamiento de redes neuronales de propagación inversa aplicadas a la dosimetría de neutrones.....	93
4.4.1.3. Espectrometría y dosimetría neutrónica con redes neuronales y esferas Bonner: un estudio para reducir el número de esferas.	93
4.4.2. <i>Co-asesoría en tesis de maestría</i>	94
4.4.2.1. Redes Neuronales Artificiales de regresión generalizada en espectrometría y dosimetría de neutrones..	94
4.5. REGISTROS DE DERECHOS DE AUTOR	95
4.6. DISCUSIÓN	96
CONCLUSIONES.....	101
5.1. PROSPECTIVAS	104
BIBLIOGRAFÍA.....	107
APÉNDICES.....	113
CURRÍCULUM VITAE	318

Índice de figuras

Figura 1.1. Clasificación de la evolución de la IA.....	2
Figura 1.2. Técnicas clásicas para espectrometría de neutrones con el SEEB	5
Figura 1.3. Espectrometría de neutrones con el SEEB y técnicas de IA.....	6
Figura 1.4. Marco conceptual de innovación y desarrollo tecnológico en EDN con IA	10
Figura 1.5. Técnicas de optimización de RNA: DRRNA Vs RNAE	11
Figura 2.1. Descripción del modelo conexionista.....	19
Figura 2.2. Modelo conexionista con 11 unidades.....	19
Figura 2.3. Modelo conexionista organizado en capas.....	19
Figura 2.4. Modelo conexionista de red	19
Figura 2.5. Redes recurrentes monocapa con estructura de retroalimentación lateral	20
Figura 2.6. Estructura de alimentación en dos capas	20
Figura 2.7. Estructura de retroalimentación de dos capas	21
Figura 2.8. Estructura de alimentación de tres capas.....	21
Figura 2.9. Estructura recurrente de una sola capa.....	21
Figura 2.10. Aprendizaje supervisado de una RNA.....	23
Figura 2.11. Aprendizaje no supervisado de RNA.....	25
Figura 2.12. Gráfica de la función Gaussiana.....	29
Figura 2.13. Arquitectura de red de la RNFBR	31
Figura 2.14. Diagrama de bloques de una RNP	34
Figura 2.15. Arquitectura básica de la RNARG	37
Figura 2.16. Poder de penetración de partículas radiactivas.....	41
Figura 2.17. Comportamiento de partículas radiactivas ante campos magnéticos	42
Figura 2.18. Espectro de los neutrones del $^{241}\text{AmBe}$, $^{239}\text{PuBe}$, $^{226}\text{RaBe}$ $^{210}\text{PoBe}$	45
Figura 2.19. Interacción de los neutrones con el tejido	47
Figura 2.20. Espectrómetro de neutrones de Bonner	52
Figura 2.21. Detección de neutrones con el SEEB.....	52
Figura 2.22. Matriz de respuesta del SEEB de la UAEN-UAZ.....	53
Figura 3.1. Esquema general de RNA aplicadas en la espectrometría neutrónica	60
Figura 3.2. 251 espectros de neutrones utilizados en el entrenamiento de RNARG	61

Figura 3.3. Matriz de respuesta del detector de ^3He del PTB.....	66
Figura 3.4. Matriz de respuesta del detector de ^3He del LANL.....	67
Figura 3.5. Matriz de respuesta del detector de $^6\text{Li}(\text{Eu})$	67
Figura 3.6. Valor óptimo del kernel de propagación constante.....	69
Figura 3.7. Código de deconvolución de espectrometría y dosimetría de neutrones Basado en RNARG	70
Figura 3.8. Ventana principal de la herramienta computacional diseñada en base a la tecnología de RNARG con aplicación en espectrometría y dosimetría neutrónica.....	72
Figura 3.9. Selección del directorio de trabajo.....	72
Figura 3.10. Selección de la matriz de respuesta con el que será entrenada la RNARG.....	73
Figura 3.11. Selección de las esferas Bonner de una medición realizada con un detector de ^3He que utiliza la matriz de respuesta GSF del compendio de la IAEA.....	74
Figura 3.12. Selección de las esferas Bonner de una medición realizada con un detector de ^3He que utiliza la matriz de respuesta PTB del compendio de la IAEA.....	74
Figura 3.13. Selección de las esferas Bonner de una medición realizada con un detector de ^3He que utiliza la matriz de respuesta LANL del compendio de la IAEA.....	75
Figura 3.14. Selección de esferas y captura de datos experimentales para entrenamiento y reconstrucción del espectro, así como el cálculo simultáneo de 15 cantidades dosimétricas.....	76
Figura 3.15. Selección de la tarea de entrenamiento deseada.....	77
Figura 3.16. Gráfica que muestra el valor del kernel de propagación constante.....	78
Figura 3.17. SEEB con detector $^6\text{Li}(\text{Eu})$	80
Figura 3.18. SEEB con detector ^3He	81

Índice de tablas

Tabla 2.1. Tipos de funciones de base radial	28
Tabla 2.2. Clasificación de los neutrones	44
Tabla 3.1. Coeficientes de conversión de fluencia a dosis (pSv-cm ²)	62

Introducción

La Inteligencia Artificial (IA), que busca entender a las entidades inteligentes, es uno de los campos más nuevos en investigación. La inteligencia se podría definir a través de las propiedades que exhibe: la habilidad de tratar con nuevas situaciones, de resolver problemas, de contestar preguntas, de crear planes, etc. La frase *inteligencia artificial* fue inventada por John McCarthy en los años 40 y hasta la fecha evade una definición concisa y formal [1]. Una definición simple podría ser: la IA es el estudio de sistemas que actúan de forma que a cualquier observador le parecería que son inteligentes e involucra utilizar métodos basados en el comportamiento inteligente de los humanos y otros animales en la solución de problemas complejos [2], [3].

Como se ilustra en la Figura 1.1, la IA se puede clasificar en tres periodos: el clásico, el romántico y el moderno. La principal área de investigación cubierta durante el periodo clásico, durante los años 50, fue relacionada a los problemas de búsqueda inteligente involucrados en juegos y prueba de teoremas; en el periodo romántico, desde mediados de los 60 hasta mediados de los 70, la gente estaba interesada en hacer “pensar” a las máquinas a través del entendimiento del lenguaje natural; el periodo moderno, que inició a mediados de los 70 y continúa hasta el presente, incluye además de lo mencionado investigación de teorías y aspectos prácticos de la IA. Este periodo está dedicado a resolver problemas relativamente simples o problemas complejos que están incluidos en sistemas más complejos y que son de interés práctico. [1], [4]–[6]



Figura 1.1. Clasificación de la evolución de la IA

La búsqueda de la IA ha tomado dos caminos fundamentales: la investigación psicológica y fisiológica de la naturaleza del aprendizaje humano, y consecuentemente el desarrollo tecnológico de sistemas informáticos cada vez más complejos. En este sentido, la IA se ha aplicado a sistemas y programas computacionales capaces de realizar tareas complejas simulando el proceso de aprendizaje humano, aunque aún se encuentra considerablemente lejos de éste. [7], [8]

El objetivo de la IA es utilizar algoritmos, heurísticas y metodologías basadas en las formas en las que el cerebro humano resuelve problemas. En las décadas más recientes se han desarrollado diversas tendencias para el desarrollo de sistemas basados en la tecnología de IA, tales como: Sistemas Expertos (SE), Lógica Difusa (LD), Algoritmos Genéticos (AG), Redes Neuronales Artificiales (RNA), entre otros. Los SE tratan de reproducir el razonamiento humano de forma simbólica, las RNA recrean la estructura del cerebro humano imitando el proceso de aprendizaje y los AG utilizan la filosofía Darwiniana de la sobrevivencia del más apto en la búsqueda de una solución óptima. [2], [9]–[15]

El objetivo de la IA es el desarrollo de paradigmas que requieren las máquinas para desarrollar tareas cognitivas en las que los humanos normalmente son mejores. Un sistema de IA debe ser capaz de hacer tres cosas: almacenar conocimiento, aplicar el conocimiento almacenado en la solución de problemas y adquirir nuevo conocimiento por medio de la experiencia. Un sistema de este tipo, tiene tres componentes clave: representación, razonamiento y aprendizaje. En esta esfera, los campos de investigación en que se han aplicado las técnicas de IA son: procesamiento de información, reconocimiento de modelos, juegos y áreas aplicadas como el

diagnóstico médico, y durante los últimos años en el área de las Ciencias Nucleares. [2], [7], [8], [16]

La teoría de RNA ha brindado una alternativa a la computación clásica para aquellos problemas en los que los métodos tradicionales han entregado resultados no muy convincentes o poco convenientes. Las aplicaciones más exitosas de las RNA son: procesamiento de imágenes y de voz, reconocimiento de patrones, planeación, interfaces adaptivas para sistemas hombre/máquina (robótica), predicción, control y optimización, filtrado de señales y recientemente en Espectrometría y Dosimetría Neutrónicas (EDN) por medio del Sistema Espectrométrico de Esferas de Bonner (SEEB) en áreas como la física de altas energías y la protección radiológica. [16]

Es bien conocido que, 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 a aquellos encontrados en esas instalaciones [17]–[19]. Sin embargo, se encuentran muchos problemas al intentar determinar el espectro de energía de neutrones de un dato medido. El conocimiento de estos espectros de neutrones se puede obtener por medio de técnicas espectrométricas, asumiendo en todos los casos que los datos medidos están linealmente relacionados al espectro que se busca determinar a través de la ecuación integro-diferencial de Fredholm de primer tipo. En general, el espectro de neutrones deseado se obtiene invirtiendo numéricamente la ecuación, utilizando un código de reconstrucción que define implícitamente una solución de la misma. [20]–[22]

Entre todas las técnicas disponibles para la espectrometría de neutrones, el SEEB es el más utilizado para los propósitos de la protección radiológica, debido a las múltiples ventajas que ofrece el tener la información espectral [23]. La parte más delicada de la espectrometría basada en el SEEB, es el proceso de reconstrucción, para esto se han desarrollado varios códigos de deconvolución computarizados basados en este sistema, cuyos puntos críticos son en general: la complejidad de los códigos, los largos

periodos de tiempo requeridos para realizar las mediciones, la necesidad de un usuario experto y la de proporcionar información real a priori.

De acuerdo a lo anterior, durante los últimos años, se han realizado intentos por desarrollar nuevos códigos de deconvolución de espectros de neutrones como: MAXED, MITOM, FRUIT, GRAVEL, que se basan en algoritmos de reconstrucción iterativos, cuyo funcionamiento requiere de un “espectro inicial”, a partir del cual se realizan las iteraciones. El problema de esta situación es que el espectro que resulta del proceso de reconstrucción depende de qué tan semejante sea el espectro inicial del espectro que se está buscando. [24]–[27]

El otro problema asociado a estos códigos, es su pobre disponibilidad y que su manejo no es fácil para el usuario. Estas consideraciones, junto con aquellas sugeridas por la experiencia en la protección radiológica alrededor de las instalaciones, sugieren que un código de reconstrucción dedicado al monitoreo de neutrones en áreas de trabajo operacionales, sería de gran ayuda para la comunidad que se dedica a la protección radiológica.

Como se ilustra en la Figura 1.2, se puede observar que en el ámbito de investigación de la espectrometría y dosimetría neutrónicas existen varias dificultades como las que se mencionan a continuación, que hacen que la solución de tales problemas no sea una tarea trivial. [26], [28]–[30]

Al observar la Figura 1.2, se puede apreciar que uno de los mayores problemas que presentan las técnicas clásicas utilizadas en la actualidad, es la alta dependencia basada en la experiencia del experimentador y de la calidad de la información “a priori” (espectro inicial), que debe ser proporcionada a los códigos de deconvolución, asimismo, habiendo obtenido el espectro, las dosis se calculan por medio de los coeficientes de fluencia a dosis, que en la mayoría de los códigos de reconstrucción

son coeficientes no actualizados lo que conlleva a subestimarla, o bien, a obtener una dosis que ya no se utiliza.

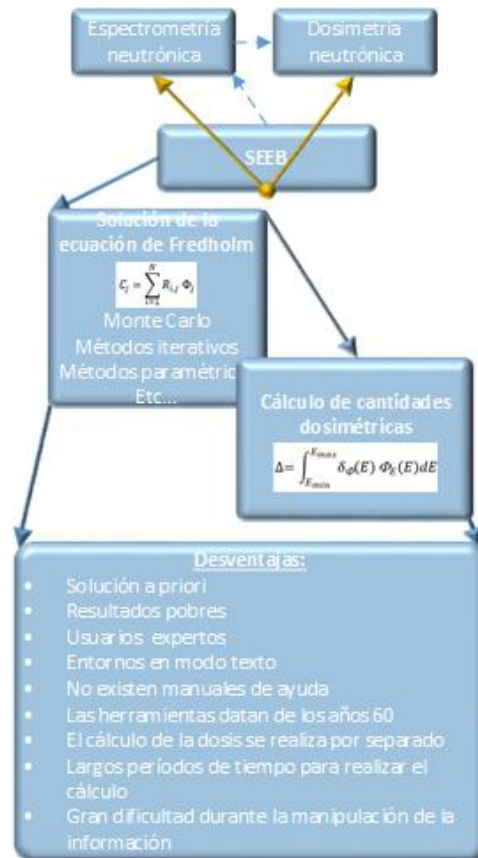


Figura 1.2. Técnicas clásicas para espectrometría de neutrones con el SEEB

La búsqueda de soluciones a los problemas inherentes a este campo de investigación, se ha realizado desde la década de los años 50. En este sentido, la espectrometría de neutrones ha tenido que hacer frente durante su desarrollo en estas últimas décadas a numerosas dificultades, mismas que provienen tanto del dominio de la teoría como de la instrumentación y en su inmensa mayoría se deben a las propiedades específicas de la interacción de los neutrones con la materia, lo que explica que la precisión conseguida hoy día dentro del campo de la dosimetría de neutrones, sea netamente inferior al encontrado en el caso de la radiación gama. [31], [31]–[33]

No obstante, las dificultades mencionadas o precisamente a causa de ellas, grupos de investigadores han producido algunos avances significativos en los últimos años. Recientemente se han utilizado métodos como los basados en la Máxima Entropía [34], [35] o en técnicas de IA como AG y/o RNA [6], [12] como métodos alternativos, mismos que pretenden resolver algunos de los problemas antes mencionados.

Como se observa en la Figura 1.3, la reconstrucción de espectros de neutrones a partir del SEEB por medio de la tecnología de IA, es una técnica alternativa que está ganando popularidad entre los investigadores, ya que ofrece mejores resultados con relación a los métodos de solución tradicionales, empleados para tal fin.

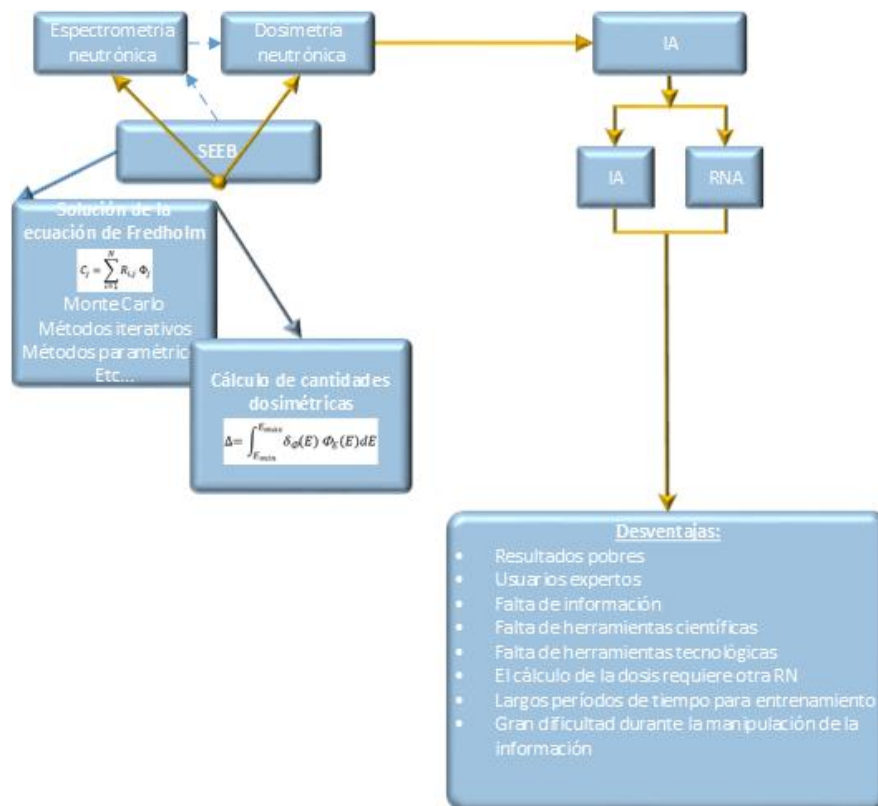


Figura 1.3. Espectrometría de neutrones con el SEEB y técnicas de IA

En la actualidad, las técnicas de IA están recibiendo gran atención por parte de los investigadores, debido a los resultados exitosos obtenidos, sin embargo, como puede observarse en la figura anterior, en el actual estado del arte que tiene que ver con el

uso de la IA en el ámbito de la espectrometría de neutrones, al emplear la tecnología de RNA, aún existen serios problemas en lo que se refiere a la selección óptima de los parámetros intrínsecos a éstas. [36]–[39]

En la actualidad los investigadores determinan estos parámetros por medio de la técnica de ensayo y error. Lo anterior implica que no es fácil para el diseñador elegir una topología de red satisfactoria, sin importar la experiencia que tenga. Por consiguiente, debe existir una forma más sencilla y eficiente de superar estas desventajas. Un investigador, con o sin experiencia, no debería emplear mucho tiempo en la selección de los parámetros óptimos, sin embargo, en la práctica el mayor porcentaje de tiempo se dedica a esta actividad, porque se carece de métodos y estrategias en este dominio del conocimiento, debido principalmente a que el procedimiento de diseño de las RNA no es un problema sencillo, y la determinación de un conjunto apropiado de valores de los parámetros estructurales y de aprendizaje de las mismas sigue siendo una tarea difícil.

Las dificultades intrínsecas asociadas con las RNA hacen difícil aplicar estas teorías de IA en el ámbito de la espectrometría neutrónica, lo que ha motivado el estudio y desarrollo de nuevas metodologías de diseño de RNA como alternativas a los problemas mencionados. Aunado a lo anterior, debido a que se trata de una tecnología emergente, se observa que se carece de herramientas científico-tecnológicas que permitan aplicar esta tecnología de forma ágil y eficiente en ambientes laborales, experimentales y de laboratorio.

Las desventajas de las técnicas descritas con anterioridad, han motivado a los investigadores a buscar nuevas alternativas en una búsqueda de solución de los problemas asociados con la espectrometría y dosimetría neutrónicas. Con la evolución de una compleja sociedad tecnológica y la introducción de nuevas nociones y herramientas teóricas innovadoras en el campo de los sistemas inteligentes, el área de desarrollo de la IA está sufriendo una gran evolución. En las últimas décadas se

han intentado procedimientos novedosos como alternativa en el ámbito de esta disciplina de estudio. [40], [41]

Se han explorado técnicas basadas en AG, RNA del tipo propagación hacia delante, entrenadas por medio del algoritmo de propagación inversa (RNAPAPI) [40], [42] y en el presente proyecto se propone y explora el uso de Redes Neuronales Artificiales de Regresión Generalizada (RNARG) [43].

Como se ha mencionado, en la solución de los problemas asociados con la espectrometría y dosimetría neutrónicas, los investigadores han utilizado RNAPAPI, sin embargo, uno de los mayores inconvenientes de una red neuronal de este tipo, es que es altamente dependiente de la topología de la red, lo que implica la determinación y optimización de una gran cantidad de parámetros.

Las RNAPAPI tienen la característica de ser sumamente flexibles, el proceso es altamente paralelo y se pueden utilizar para resolver una gran variedad de problemas, sin embargo, este tipo de topología de RNA presenta algunos problemas: la selección óptima de los parámetros de diseño de una RNAPAPI es fundamental para que pueda alcanzar su mejor desempeño. En una red neuronal multicapa de este tipo, el número de neuronas en las capas ocultas, así como el número de éstas, es un parámetro que lo define el diseñador. De manera similar, los parámetros de control de la red, como la tasa de aprendizaje y el momento, son parámetros que deben definirse. Para alcanzar el mejor desempeño de la red, se tienen que elegir valores apropiados para estos parámetros, sin embargo, no es fácil para el diseñador elegir una topología de red satisfactoria. [39], [44], [45]

Una buena elección de estos parámetros podría acelerar en gran medida el proceso de aprendizaje para alcanzar el objetivo deseado, aunque no existe una respuesta universal para tales tópicos, por lo que la técnica de ensayo y error ha sido la técnica más utilizada para conseguir la mejor combinación de los parámetros de la arquitectura

de la red, lo que produce redes con pobre desempeño y baja capacidad de generalización que afecta su aplicación en problemas reales. [46], [47]

Por otro lado, el entrenamiento puede requerir cantidades sustanciales de tiempo para aproximarse de forma gradual a buenos valores de pesos sinápticos. Además, el tamaño de los datos de entrenamiento tiene que ser muy grande y en muchos problemas es casi imposible proporcionar suficientes muestras de entrenamiento, como es el caso de los problemas relacionados con la espectrometría y dosimetría de neutrones. [5], [6]

Otro inconveniente, es el hecho de que añadir nueva información requiere volver a entrenar la RNA y esto resulta caro computacionalmente hablando para las RNAPAI pero no para las RNARG, las cuales pertenecen a la categoría de las Redes Neuronales Artificiales Estadísticas (RNAE). Las estrategias de las RNARG pueden ser aplicables a problemas que contienen cualquier número de categorías como en el caso de la espectrometría y dosimetría neutrónicas [48].

A diferencia de las RNAPAI, las RNARG utilizan un método estadístico en su algoritmo de predicción con base en la estrategia de Bayes para la clasificación de patrones. Para ser capaz de utilizar esta estrategia es necesario estimar con precisión la función de densidad de probabilidad. La única información disponible para estimar esta función son las muestras utilizadas para el entrenamiento de la RNA [34]. Sin embargo, debido a que es una tecnología emergente, la carencia de herramientas científicas y tecnológicas que estimulen su aplicación práctica en situaciones reales como en el caso de la espectrometría neutrónica, representa un serio obstáculo para su desarrollo.

Justificación

Como se ilustra en la Figura 1.4, la presente tesis doctoral se desarrolla en el marco del proyecto de investigación denominado “Estudio, análisis, diseño y optimización de arquitecturas de redes neuronales artificiales en la espectrometría y dosimetría de

neutrones”. Dicho proyecto es apoyado por el Fondo de Ciencia Básica de CONACyT bajo el contrato 241771. El principal objetivo del proyecto se centra en la creación del Laboratorio de Innovación y Desarrollo Tecnológico en Inteligencia Artificial (LIDTIA) mismo que busca fomentar y promover la innovación y desarrollo tecnológico empleando técnicas avanzadas de Minería de Datos basado en tecnología de Inteligencia Artificial en la solución de problemas de Ingeniería. El segundo objetivo fundamental, es la formación de recursos humanos altamente calificados, realizando el estudio, análisis, diseño e implementación de técnicas de optimización de RNA con su aplicación principal en EDN.

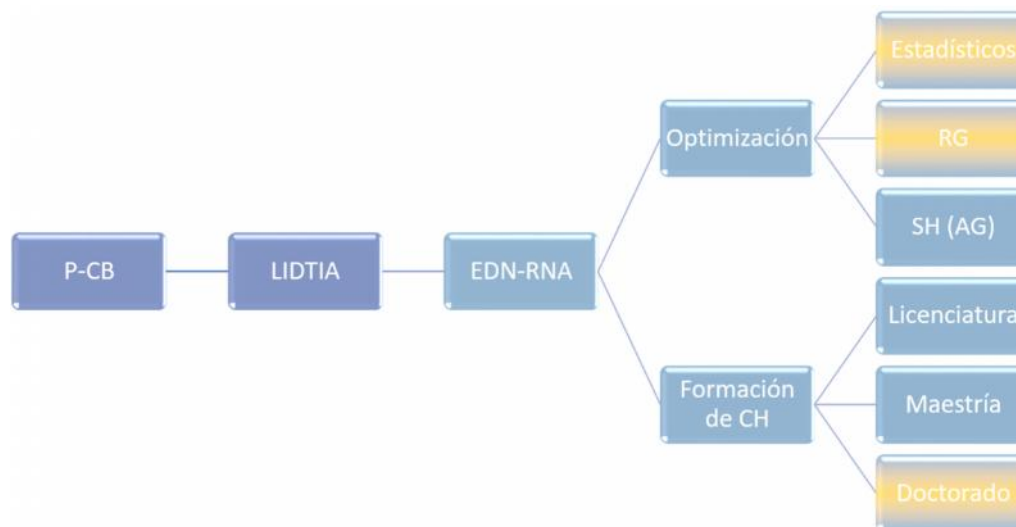


Figura 1.4. Marco conceptual de innovación y desarrollo tecnológico en EDN con IA

El presente proyecto de investigación se centra en el estudio, análisis, diseño e implementación de una metodología basada en RNARG como una propuesta alternativa y novedosa aplicada en EDN. Lo anterior es importante debido a que actualmente, en el ámbito de la EDN, los instrumentos de radioprotección tienen respuestas dependientes del espectro de neutrones. Todo ello hace difícil la interpretación de las indicaciones de estos instrumentos, si no se conoce la distribución espectral de fluencia de los neutrones en los puntos de medida. [20]

Resulta además que como el espectro puede cambiar de manera apreciable dentro de una instalación nuclear, la espectrometría de neutrones es de interés capital para la comprensión y correcta calibración de los instrumentos usados para medir la dosis, ya que únicamente este método permite una evaluación precisa de las magnitudes dosimétricas de interés y al mismo tiempo elaborar los protocolos y estrategias adecuados para la protección radiológica. [49]

Como se muestra en la Figura 1.5, actualmente se están utilizando nuevos métodos basados en tecnologías de IA para realizar la espectrometría y dosimetría de neutrones, utilizando principalmente la teoría de RNAPAPI. En años recientes el uso de la tecnología de RNA en EDN se ha convertido en un procedimiento alternativo con el que se han obtenido resultados satisfactorios. Sin embargo, a pesar de sus ventajas, el procedimiento mismo de diseño de las redes no es un problema trivial, ya que determinar un conjunto apropiado de valores de los parámetros estructurales y de aprendizaje de las mismas sigue siendo una tarea compleja.

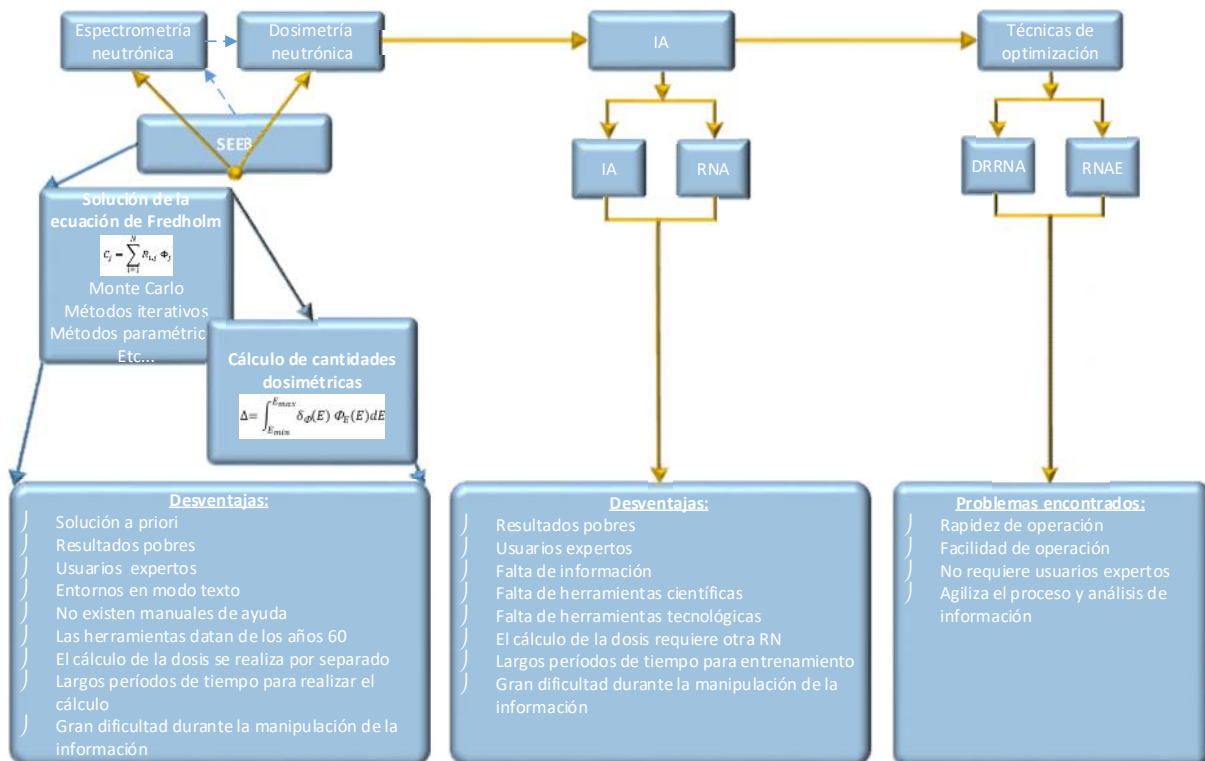


Figura 1.5. Técnicas de optimización de RNA: DRRNA Vs RNAE

La estructura de la red, también conocida como topología de red, así como sus parámetros de aprendizaje, son factores que contribuyen de manera significativa con el desempeño de la misma, sin embargo, se ha observado que los investigadores en esta área de conocimiento realizan la selección de los parámetros de la red a través de la técnica de ensayo y error, empleando en este proceso largos periodos de tiempo, obteniendo redes neuronales de pobre desempeño y baja capacidad de generalización. [2], [37]

La contribución de este trabajo de tesis doctoral se centra en el diseño de una metodología que permita aplicar las RNARG en la EDN y un código de deconvolución de espectros de neutrones y cálculo de distintas cantidades dosimétricas denominado “Espectrometría y dosimetría de neutrones basado en redes neuronales de regresión generalizada”, (NSDGRANN, de sus siglas en inglés: Neutron Spectrometry and Dosimetry by means of Generalized Regression Artificial Neural Networks).

El código mencionado tendrá las siguientes características: será diseñado en una interface gráfica de usuario que cuente con una forma conveniente de entrada y salida de datos, que sea fácil de utilizar, que el programa se ejecute de forma rápida, que no se requiera introducir ningún conocimiento a priori para la deconvolución del espectro, que éste se reconstruya con precisión y que además del cálculo del espectro se calculen distintas cantidades dosimétricas, a partir tan solo de las tasas de conteo provenientes de un SEEB, de tal manera que sea posible caracterizar el espectro de neutrones.

La reconstrucción de espectros de neutrones y el cálculo de dosis equivalentes a partir de las tasas de conteo provenientes del SEEB, empleando la tecnología de RNAPAPI diseñadas por medio de la MDRRNA, es una técnica alternativa que ha estado recibiendo gran atención durante los últimos años debido a los exitosos resultados obtenidos. Sin embargo, las dificultades intrínsecas asociadas con las RNAPAPI hacen difícil aplicar las teorías de IA en el ámbito de la espectrometría neutrónica, lo que ha motivado el estudio y desarrollo de metodologías alternativas explorando distintos tipos

de arquitecturas de RNA como es el caso de las redes estadísticas que tienen la característica de ser no paramétricas, esto es, a diferencia de las RNAPAPI en las RNARG no se requiere determinar y optimizar todo el conjunto de parámetros mencionado con anterioridad.

Debido a que se trata de una tecnología emergente, se debe resaltar que se carece de herramientas científico-tecnológicas que permitan aplicar esta innovación tecnológica de forma ágil y eficiente, en ambientes laborales, experimentales y de laboratorio. En vista de lo novedoso del método, se observa que el usuario final carece de una metodología basada en la tecnología de RNARG que le permita llevar a cabo las tareas mencionadas y con ello simplificar significativamente los procedimientos y tiempos de respuesta para la obtención del espectro y la dosis deseados.

De igual forma, se tiene la necesidad de diseñar un código de deconvolución personalizado, en un entorno gráfico, amigable y fácil de utilizar, que no requiera experiencia por parte del usuario, y que además sea rápido, con alto desempeño y sea capaz de resolver con eficiencia los problemas de EDN. En vista de lo expuesto con anterioridad, se formula la siguiente pregunta científica.

Pregunta científica

En la solución de problemas de ingeniería empleando técnicas avanzadas de inteligencia artificial, ¿cuáles son las ventajas que se obtienen al implementar RNARG en comparación con RNAPAPI? Para responder a la pregunta anterior, se plantea la siguiente hipótesis.

Hipótesis

El desempeño de las RNARG en comparación con las RNPAPI es mejor debido a que se reduce el tiempo requerido para entrenar las redes y se incrementa la eficiencia de la misma, al no requerir la determinación de parámetros como en el caso de las RNAE.

Para contestar la pregunta formulada y en virtud de que se trata de una tecnología emergente, se debe resaltar el hecho de que se carece de herramientas científicas y tecnológicas que estimulen su aplicación práctica en situaciones reales por lo que es necesario realizar la innovación y el desarrollo de herramientas tecnológicas. Es por ello que se formula el siguiente problema científico.

Con la intención de confirmar la validez de la hipótesis científica de esta investigación, el objetivo general es el siguiente.

Objetivo general

El objetivo primario del presente trabajo de investigación se centra en dos aspectos fundamentales: en primer lugar, estudiar, analizar, diseñar, implementar y aplicar una metodología alternativa utilizando arquitecturas de RNARG que sean capaces de resolver con alto rendimiento y capacidad de generalización los problemas relacionados con la EDN.

El segundo objetivo es el diseño e innovación de un código de deconvolución de EDN basado en la tecnología de RNARG que permita aplicar el conocimiento adquirido por la red en ambientes laborales, experimentales, y de laboratorio reales.

Para alcanzar el objetivo general, se proponen los siguientes objetivos particulares:

Objetivos particulares

-) Extraer información del compendio de neutrones de la IAEA.
-) Realizar el pre procesamiento de la información extraída.
-) Estudiar, analizar e implementar técnicas de optimización para el diseño de arquitecturas de redes neuronales artificiales de regresión generalizada.
-) Definir el valor crítico de optimización de la red neuronal a ser entrenada.
-) Aplicar las estrategias de diseño analizadas en el punto anterior, en la optimización de una RNARG en el ámbito de la espectrometría neutrónica.

-) Diseñar un código de deconvolución para EDN mediante la tecnología de RNARG que pueda ser utilizada en ambientes experimentales reales.
-) Comparar los resultados obtenidos mediante el código desarrollado frente a los obtenidos con técnicas clásicas.

Revisión de literatura

2.1. Inteligencia artificial y conexionismo

Como se ha mencionado previamente, la IA es uno de los campos más novedosos de la investigación que intenta entender a las entidades inteligentes. El objetivo de estudio de la IA es el uso de algoritmos, heurísticas y metodologías basadas en las formas en que los humanos resuelven problemas. En las últimas décadas, las áreas de particular importancia de la IA incluyen a los sistemas multi-agente, la vida artificial, la visión computacional, la planeación, los juegos y el aprendizaje de máquinas. [50], [51]

2.2. Aprendizaje de máquinas y conexionismo

El aprendizaje y la inteligencia están íntimamente relacionados. El aprendizaje es una característica inherente de los humanos. A través de ésta, la gente a medida que realiza actividades similares, adquiere la habilidad de mejorar su desempeño a través del auto-mejoramiento del comportamiento futuro en base a experiencias pasadas. En la mayoría de los problemas de aprendizaje, la tarea es aprender a clasificar entradas de acuerdo con un número finito de clasificaciones, algunas ocasiones infinito. [52]

De forma típica a un sistema de aprendizaje se le proporciona un conjunto de datos de entrenamiento, los cuales se han clasificado previamente a mano. El sistema intenta

entonces aprender a partir de esos datos de entrenamiento a clasificarlos, generalmente una tarea relativamente fácil, y también a clasificar nuevos datos que no se han visto previamente. [53]

Se puede dotar a las máquinas de los principios del aprendizaje para mejorar su desempeño. Un sistema capaz de aprender es inteligente y generalmente se espera que sea capaz de aprender en base a la experiencia pasada. A este tipo de aprendizaje se le conoce regularmente como Aprendizaje de Máquinas (AM) que es una parte importante de la IA y que se puede clasificar de forma general en tres categorías: supervisado, no supervisado y aprendizaje reforzado. [54]

El aprendizaje supervisado requiere un entrenador que proporciona las instancias de entrenamiento de entrada-salida. El sistema de aprendizaje adapta sus parámetros a través de algunos algoritmos para generar los patrones de salida deseados a partir de un patrón de entrada dado. En ausencia de entrenadores, la salida deseada de una instancia de entrada dada no se conoce, y en consecuencia el aprendiz tiene que adaptar sus parámetros de forma autónoma. Tal tipo de aprendizaje se conoce como aprendizaje no supervisado. [41], [47]

En aprendizaje reforzado elimina la brecha entre las categorías supervisada y no supervisada. En el aprendizaje reforzado el aprendiz no sabe explícitamente las instancias de entrada-salida, sino que recibe alguna forma de realimentación a través del entorno. Las señales de realimentación ayudan al aprendiz a decidir si su acción en el entorno es gratificante o de castigo. El aprendiz adapta entonces sus parámetros en base a los estados (gratificantes / de castigo) de sus acciones.

Recientemente, el método conexionista para la construcción de máquinas inteligentes con modelos estructurados como las RNA está recibiendo gran atención. Los métodos conexionistas están basados en los fundamentos de cómo ocurren los cálculos en las

redes neuronales biológicas. Las conexiones juegan un rol esencial en los modelos conexionistas, de aquí el nombre de conexionismo. [55]

El término conexionismo fue presentado por Donald Hebb en los años 40 y es un conjunto de métodos en el ámbito de la IA de modelos mentales o fenómenos de comportamiento como los procesos emergentes de redes interconectadas a partir de simples unidades de procesamiento. El principio central conexionista es que los fenómenos mentales se pueden describir a través de unidades simples y uniformes formando redes interconectadas. [2], [3]

Las unidades son para un modelo conexionista lo que las neuronas son para una red neuronal biológica: las estructuras básicas de procesamiento de la información. Debido a que el flujo de información en una red ocurre a través de sus conexiones, el enlace a través del cual fluye la información de un miembro de la red al siguiente se conoce como sinapsis. Las sinapsis son para las redes neuronales lo que un cable ethernet o de teléfono es para una red de computadoras. Sin las sinapsis de otras neuronas, sería imposible para una neurona recibir entradas y enviar salidas de y hacia otras neuronas respectivamente. Dado el rol crucial que las conexiones juegan en una red de neuronas, la sinapsis en una red neuronal biológica es tan importante como las neuronas mismas. [15], [56]

La mayoría de los modelos conexionistas son simulaciones computacionales ejecutadas en computadoras digitales. En un modelo conexionista computacional, las unidades generalmente se representan por medio de círculos como se ilustra en la Figura 2.1. Debido a que una unidad por sí misma no constituye una red, los modelos conexionistas típicamente están compuestos de muchas unidades como se aprecia en la Figura 2.2. Sin embargo, las RNA están organizadas en capas de neuronas. Por esta razón, los modelos conexionistas se organizan en capas de unidades como se aprecia en la Figura 2.3. La Figura 2.3 todavía no se considera una red debido a que ningún grupo de objetos califica como una red a menos que cada uno de sus miembros

esté conectado con los otros, es la existencia de las conexiones lo que constituye a una red como se aprecia en la Figura 2.4.



Figura 2.1. Descripción del modelo conexionista




Figura 2.2. Modelo conexionista con 11 unidades




Figura 2.3. Modelo conexionista organizado en capas




Figura 2.4. Modelo conexionista de red

En la Figura 2.4 se puede observar que las conexiones de una red son los conductos a través de los cuales fluye la información entre los miembros de una red. En la ausencia de tales conexiones, ningún grupo de objetos califica como una red. Existen

dos tipos de conexiones de red: de entrada y de salida. Una conexión de entrada es un conducto a través del cual un miembro de la red recibe información. Una conexión de salida es un conducto a través del cual un miembro de la red envía información. Aunque es posible que las conexiones de una red sean de entrada y/o salida, una unidad no califica como miembro de una red si no es capaz de recibir información de otras unidades o enviarla a otras unidades. [57]

Existen muchas formas de conexionismo, sin embargo, las formas más comunes utilizan modelos de RNA. La forma de las unidades y las conexiones puede variar de modelo a modelo como se ilustra en las figuras 2.5 a 2.9, en donde se puede apreciar que es posible que exista cualquier número de unidades dentro de cada capa, y cada unidad de cada capa generalmente se conecta a través de una conexión con un peso sináptico a cada nodo de la capa siguiente. Los datos se ingresan a la red a través de la capa de entrada.




Figura 2.5. Redes recurrentes monocapa con estructura de retroalimentación lateral




Figura 2.6. Estructura de alimentación en dos capas




Figura 2.7. Estructura de retroalimentación de dos capas




Figura 2.8. Estructura de alimentación de tres capas




Figura 2.9. Estructura recurrente de una sola capa

Dependiendo de la naturaleza de los problemas, los modelos de RNA se organizan en distintos arreglos estructurales (arquitecturas o topologías) [58]. La arquitectura de RNA define su estructura incluyendo el número de capas ocultas, el número de neuronas ocultas y el número de neuronas en las capas de entrada y de salida. Existen varios tipos de arquitecturas de RNA. Como se muestra en las figuras 2.5 a 2.9, la mayoría de los modelos de redes neuronales más ampliamente utilizados se pueden dividir en dos categorías principales: Redes Neuronales Artificiales de propagación hacia adelante (RNAPA) y las redes neuronales con retroalimentación (RNAR) [57]–[62].

Como se puede apreciar en las figuras 2.6 y 2.8, las RNAPA le permiten viajar a las señales de una sola forma; los datos ingresan a las entradas y pasan a través de la red, capa por capa, hasta que alcanzan la salida. No existe realimentación o lazos entre las capas. Estos dos modelos de red se utilizan ampliamente en reconocimiento de patrones y clasificación. Las RNAR pueden tener señales viajando en ambas direcciones al introducir lazos de realimentación en la red como se muestra en las figuras 2.5, 2.7 y 2.9. Este tipo de redes son dinámicas, su estado está cambiando continuamente hasta que alcanzan el punto de equilibrio y permanecen en éste hasta que se experimentan cambios en la entrada siendo necesario encontrar un nuevo equilibrio.

En la mayoría de los modelos conexionistas, las unidades se organizan en tres capas: una capa de entrada, una o más capas ocultas y una capa de salida [57]–[62]. Las figuras 2.4 y 2.8 muestran una RNAPA de tres capas la cual está compuesta de las tres capas neuronales mencionadas con anterioridad, en donde cada neurona está conectada a cada neurona anterior y la información fluye hacia delante en la red a partir de las neuronas de entrada hacia las neuronas de la capa oculta hasta las neuronas de salida. Las neuronas de la capa oculta procesan los datos de entrada que reciben como la suma de las salidas de los pesos sinápticos de la capa de entrada. Los nodos de la capa de salida procesan las entradas que reciben como la suma de los pesos sinápticos de las neuronas de las capas ocultas y proporcionan la salida del sistema.

Como se ha mencionado, los principios del aprendizaje se pueden aplicar a las máquinas para mejorar su desempeño [16]. En las RNAPA, el aprendizaje de la red es un proceso sumamente importante, el cual se puede dividir en dos categorías principales: aprendizaje supervisado y no supervisado. Con el aprendizaje supervisado, la RNA deben ejecutar un proceso de entrenamiento antes de que presente utilidad alguna. El entrenamiento consiste en presentar un conjunto de entradas-salidas a la red neuronal. La Figura 2.10 muestra la naturaleza que distingue el entrenamiento supervisado, el cual incorpora un instructor externo que conoce las

entradas y salidas y cuyo objetivo es descubrir una relación entre estos datos (entradas-salidas). De este modo, la salida actual de la RNA se compara con la salida deseada, proporcionada por el instructor.

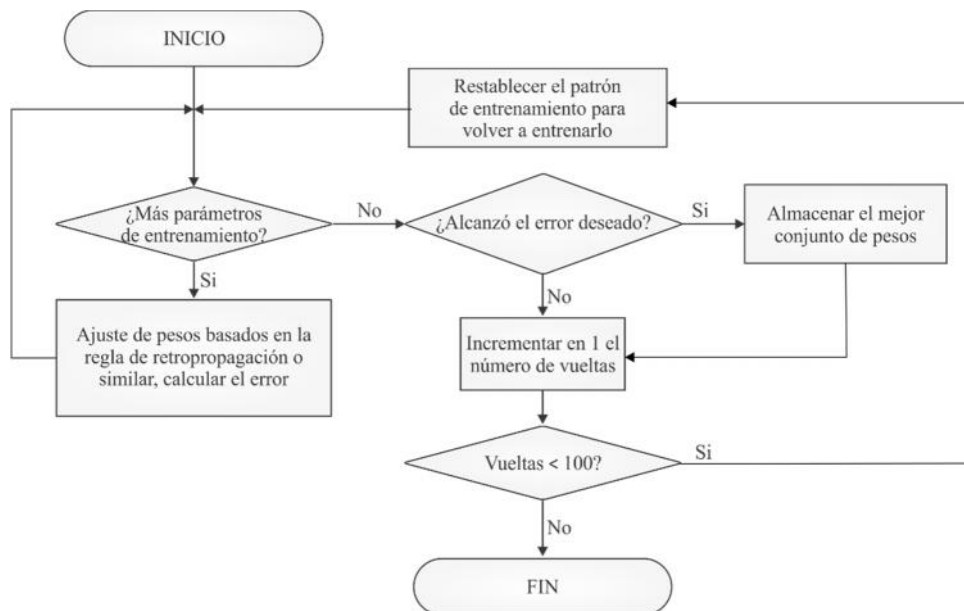


Figura 2.10. Aprendizaje supervisado de una RNA

Un problema importante que se presenta con el aprendizaje supervisado es el problema de la convergencia del error: la reducción del error entre los valores calculados y deseados. El desempeño de la red se evalúa en base a la comparación entre la salida calculada por la RNA y la salida deseada [16], [57]–[62]. Existen varios tipos de mediciones de predicción de la exactitud del error, las mediciones más comunes son las siguientes:

1. Determinación de coeficiente de correlación (R^2)

$$R^2 = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (1)$$

2. Error medio cuadrático (MSE)

$$M = \frac{1}{n} \sum_{i=0}^n (Y_i - \hat{Y}_i)^2 \quad (2)$$

3. Raíz cuadrada del error medio cuadrático (RMSE)

$$R = \left[\frac{1}{n} \sum_{i=0}^n (Y_i - \hat{Y}_i)^2 \right]^{1/2} \quad (3)$$

4. Error medio de porcentaje absoluto (MAPE)

$$M \% = \frac{1}{n} \sum_{i=0}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \times 100 \quad (4)$$

En donde Y_i es el valor actual de la salida, \hat{Y}_i es el valor obtenido por la red y (n) es el número de observaciones.

A diferencia del aprendizaje supervisado, el aprendizaje no supervisado que se utiliza en el ámbito de las RNA no requiere un instructor externo, sino que se basa únicamente en información local. Como se puede observar en la Figura 2.11, en el aprendizaje no supervisado únicamente se conoce la entrada y el objetivo es descubrir patrones en las características de los datos de entrada. A este fenómeno también se le conoce como auto-organización, en el sentido de que auto-organiza los datos presentados a la red y detecta sus propiedades colectivas emergentes. El objetivo del aprendizaje no supervisado es hacer que una computadora o máquina aprenda cómo hacer algo que no se le ha indicado como hacer. Las aplicaciones más comunes para el aprendizaje supervisado son la clasificación, la minería de datos y los mapas auto-organizativos también conocidos como mapas de Kohonen.

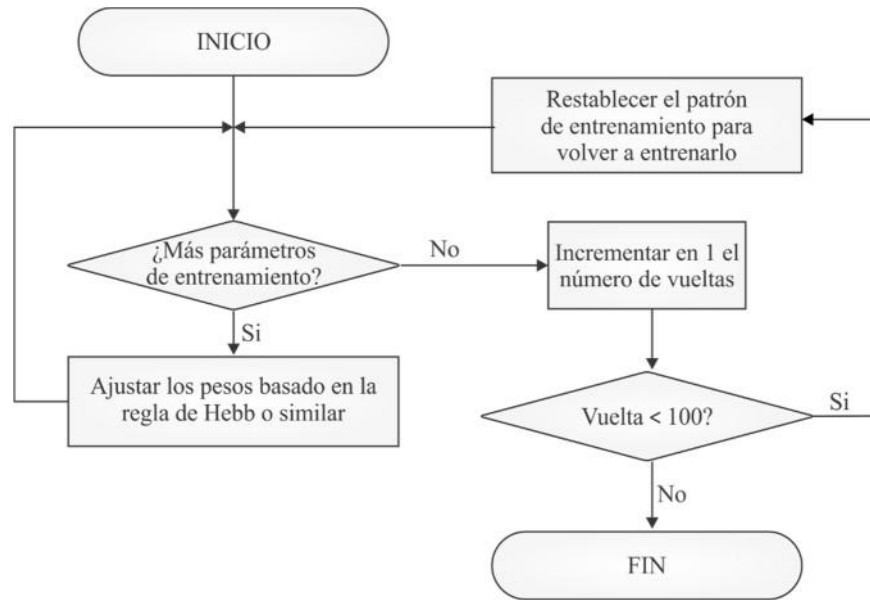


Figura 2.11. Aprendizaje no supervisado de RNA

En las RNAP con entrenamiento supervisado, existen dos tipos diferentes de RNA: las RNAPA entrenadas por medio del algoritmo de propagación inversa (RNAPAPI) y las Redes Neuronales Estadísticas (RNE) [57]–[59]. Las RNAPAPI utilizan ecuaciones que se conectan utilizando factores de pesos sinápticos. La selección de estos factores de pesos hace muy poderosas a este tipo de redes. El perceptrón multicapa es la arquitectura de RNA más común y exitosa dentro de las topologías RNAP; mientras que la técnica más común de aprendizaje supervisado utilizado en el entrenamiento de RNA es el algoritmo de entrenamiento de propagación inversa (PI) [16], [57]–[62].

La PI es un método sistemático para entrenar RNAPA multicapa como se ilustra en la figura 2.7. Debido a que es un algoritmo de entrenamiento supervisado, se deben proporcionar los patrones de entrada y de salida. Para un patrón de entrada dado, el vector de salida se estima a través de una propagación hacia delante en la red. Después de que termina la propagación hacia delante, se estima el vector de error en la capa de salida tomando la diferencia de los componentes del patrón deseado con y el vector de salida generado por la red. Entonces se propaga hacia atrás una función de errores de las neuronas de la capa de salida a través de la red en cada capa para ajustar los pesos sinápticos en cada capa correspondiente. La política de adaptación

de los pesos en el algoritmo de PI se obtiene siguiendo el principio del método de pasos descendentes encontrando el mínimo de una función multi valorada.

La RNAPAPI está compuesta de neuronas organizadas en una capa de entrada y de salida y en una o más capas ocultas como se muestra en la Figura 2.8. Las neuronas realizan algún tipo de cálculo utilizando las entradas para calcular una salida que representa al sistema. Las salidas se llevan a la siguiente neurona. Un borde indica a que neuronas se conecta la salida. Los arcos trasportan los pesos sinápticos.

De forma general, el aprendizaje de PI está compuesto de dos fases: pasar la información hacia delante y pasarla posteriormente hacia atrás. En el paso hacia delante de la información, se aplica un patrón de actividad a los nodos sensoriales de la red, que producen salidas como las respuestas actuales de la red. Durante el paso de la información hacia atrás, los pesos sinápticos se ajustan de acuerdo con una regla de corrección de error.

Las RNAPAPI tienen la característica deseable de ser flexibles. Se pueden utilizar en tareas como el reconocimiento de patrones, así como en problemas para la toma de decisiones. Otra ventaja a diferencia de otras RNA es que el procesamiento de la información es altamente paralelo, sin embargo, tienen algunas deficiencias como: el entrenamiento de este tipo de RNA puede requerir cantidades sustanciales de tiempo [63], el tamaño de los datos de entrenamiento tiene que ser grande y como requisito para realizar el entrenamiento, es necesario determinar un conjunto de datos de estructura y de entrenamiento de la red (determinar su arquitectura), que en la actualidad representa el mayor de los inconvenientes de este tipo de arquitecturas.

Por otro lado, las RNE utilizan métodos estadísticos para seleccionar las ecuaciones dentro de la estructura de la RNA y no se calculan de forma diferente a las de las arquitecturas del tipo RNAPAPI. [64]

2.3. Redes neuronales estadísticas

Las RNE son un importante tipo de redes neuronales basadas en métodos estadísticos y la teoría de la probabilidad [65]. Tres de los tipos más importantes son: las redes neuronales de función de base radial, las redes neuronales probabilísticas y las redes neuronales de regresión generalizada [43].

2.3.1. Redes neuronales de función de base radial

Las redes neuronales de función de base radial (RNFBR) fueron presentadas por Bromehead y Lowe en 1988 siendo ésta una alternativa popular de las redes neuronales de propagación inversa [48]. El comportamiento de este tipo de red es dependiente de los pesos sinápticos y de la activación de una función de transferencia F , especificada para cada una de las neuronas [66]. La función de activación mapea la suma de los pesos sinápticos que pasan a través de la misma y el valor de la salida (L) se propaga a la siguiente capa.

Existen varios tipos de funciones de transferencia de activación [67], las cuales se pueden clasificar en 4 categorías comunes:

1. Función de transferencia lineal (FTL)
2. Función de transferencia de umbral (FTU)
3. Función de transferencia sigmoideal (FTS)
4. Función de transferencia de base radial (FTBR)

La FTBR es una clase especial de funciones de activación que forman un conjunto de funciones base, cada una para cada conjunto de datos. La forma general de esta función es:

$$G(\|X - \mu\|) \tag{5}$$

Donde $G(\cdot)$ es una función radial simétrica positiva no lineal (kernel); X es el patrón de entrada y μ es el centro de la función. Otra propiedad importante de la FTBR es que su salida es simétrica alrededor del centro asociado μ . Entonces, $f(X_i)$ podría ser una combinación lineal de las salidas de todas las funciones base:

$$f(x) = \sum_{i=1}^n w_i G(\|X - \mu\|) \quad (6)$$

Existen varios tipos comunes de funciones de base radial, las cuales se muestran en la Tabla 2.1.

Tabla 2.1. Tipos de funciones de base radial

Nombre de la función	Expresión matemática
Spline de placa delgada (TPS)	$G(x) = (x - \mu)^2 \ln(x - \mu)$
Multi-cuadrático	$G(x) = \sqrt{(x - \mu)^2 + \sigma^2}$
Inverso multi-cuadrático	$G(x) = \frac{1}{\sqrt{(x - \mu)^2 + \sigma^2}}$
Gaussiana	$G(x) = e^{-\frac{(x - \mu)^2}{\sigma^2}}$

En donde los parámetros de la función son el centro (μ) y el radio (σ^2). Una función Gaussiana, también llamada “curva en forma de campana” o distribución normal, es el tipo de funciones de base radial más común y utilizada. Es apropiada no solo en la generalización de un mapeo global sino en refinar las características locales. La función Gaussiana tiende a ser local en su respuesta y es biológicamente más aceptable que otras funciones. La FTBR es única, debido a que, a diferencia de las otras, disminuye monótonicamente con la distancia a partir del centro, y forma la clásica forma de curva de campana, la cual mapea grandes valores en pequeños, y mapea valores de medio rango en grandes. En la Figura 2.12 se muestra una gráfica de la función Gaussiana.




Figura 2.12. Gráfica de la función Gaussiana

La forma matemática de esta función para el caso de una sola variable está dada por:

$$f(x) = \frac{1}{\sqrt{2\pi^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (7)$$

Donde

$$\mu = E(X) = \int_{-\infty}^{\infty} X \cdot f(x) dx \quad (8)$$

$$\sigma^2 = E(X - \mu)^2 = \int_{-\infty}^{\infty} (X - \mu)^2 \cdot f(x) dx \quad (9)$$

μ es la media (centro) de la distribución

σ^2 es la varianza (ancho del radio) de la distribución

Extendiendo la fórmula 7 a múltiples dimensiones, se puede obtener la probabilidad de densidad Gaussiana general:

$$f(\underline{x}) = \frac{1}{(2\pi)^{p/2} |\Sigma|^{p/2}} e^{-\frac{1}{2} (\underline{x} - \underline{\mu})^T \Sigma^{-1} (\underline{x} - \underline{\mu})} \quad (10)$$

Donde

p es el número de dimensiones

μ es la media vector p -dimensional

Σ la covarianza de la matriz $p \times p$.

Las RNFBR son útiles en la solución de problemas en donde la entrada está corrompida con ruido aditivo y se pueden utilizar para aproximar funciones y reconocer patrones [67]. Como se muestra en la Figura 2.13, las RNFBR tienen una arquitectura del tipo propagación hacia adelante, y está compuesto de muchas neuronas interconectadas y organizadas en tres capas sucesivas. La primera capa es la capa de entrada. Existe una neurona en la capa de entrada para cada variable predictora. La segunda capa es la capa oculta. Esta capa tiene un número variable de neuronas. Cada neurona está compuesta de una función de base radial centrada en un punto con tantas dimensiones como variables predictoras.

La distancia Euclidiana estándar se utiliza para medir qué tan lejos del centro se localiza un vector de entrada. El valor que sale de la neurona en la capa oculta se multiplica por un peso (W_i) asociado con la neurona y con un valor de sesgo que se multiplica por el peso (W_0), los cuales pasan a la capa de sumatoria que suma los valores ponderados y presenta esta suma como las salidas de la red.




Figura 2.13. Arquitectura de red de la RNFB

El entrenamiento de las RNFB es radicalmente diferente del entrenamiento realizado en las Redes Neuronales de Propagación Inversa (RNPI) [43], [48], [67]–[69]. En las RNFB el entrenamiento se realiza en dos etapas: en la primera, se calculan los parámetros de la FBR, incluyendo los centros y factores de escalamiento. Los diversos parámetros tales como el número de neuronas en la capa oculta, las coordenadas de los centros de cada función de la capa oculta, el radio (ancho) de cada función en cada unidad oculta y los pesos entre las neuronas ocultas y de salida se determinan a través del proceso de entrenamiento.

La segunda etapa, estima los pesos entre las capas ocultas y de salida. A diferencia de las RNPI, en el entrenamiento de las RNFB no existe cambio en el valor de los pesos sinápticos como en el caso de las RNPI que utilizan el método de gradiente para la optimización de la función de transferencia. En las RNFB, el entrenamiento lo resuelve por sí mismo seleccionando los centros y calculando los pesos de la neurona de salida. [67]

El centro (μ), el ancho del radio () de la FBR y los pesos finales son los parámetros del modelo. Se han diseñado muchos algoritmos para determinar estos parámetros, reduciendo el error entre el valor objetivo y el valor de salida. Es importante resaltar el hecho de que la correcta determinación del centro es importante para el éxito de la RNFBR. Existen varios métodos para elegir los centros apropiados de la red tales como la selección aleatoria a partir del conjunto de datos de entrenamiento, fijados de forma aleatoria y el método de agrupación. [43], [48], [67]–[69]

La determinación del ancho es de gran importancia para el entrenamiento exitoso de la RNFBR. Si los valores del ancho son grandes, entonces el modelo no será capaz de encajar estrechamente la función. Por otro lado, un valor grande del parámetro del ancho daría una mejor generalización, pero generaría una salida más pobre. [48], [64]–[66]

Un valor pequeño del ancho da un buen recuerdo de los patrones de entrenamiento, pero mala generalización y el modelo sobre ajustará los datos debido a que cada punto de entrenamiento tendrá mucha influencia. Existen varios métodos para determinar el ancho. Dos de los métodos más comunes son: el método fijo y el promedio de la distancia. [65]

El número de neuronas ocultas es muy importante y juega una regla principal en el desempeño de las RNFBR. Es muy difícil encontrar un número apropiado de neuronas ocultas. Si el número de neuronas ocultas es muy bajo, la red no puede alcanzar el nivel deseado de desempeño debido a un número insuficiente de neuronas ocultas. Muchos investigadores asumen que el número de neuronas ocultas es fijo y se elige de antemano. [2], [4], [70]

Existen varios tipos de aprendizaje que se pueden utilizar en las RNFBR tales como las redes neuronales de regresión generalizada (RNRG), mínimos cuadrados ortogonales, agrupación de k-medios. [43], [48], [56], [64], [67]–[69]

2.3.2. Redes neuronales probabilísticas

En 1990 Specht presentó por primera vez las Redes Neuronales Probabilísticas (RNP). Está estrechamente relacionada con la regla de la “estrategia de Bayes para la clasificación de patrones” y con la teoría de estimación de la función de densidad de probabilidad no paramétrica de Parzen. Realiza la clasificación donde la variable objetivo es categórica. [34], [43], [48], [67], [69]

Las RNP a menudo son más precisas que las RNPI y es mucho más rápido entrenar RNP que RNPI. La mayor ventaja de las RNP es el hecho de que la salida es probabilística, lo que hace fácil la interpretación de la salida, y la velocidad de entrenamiento.

Entrenar una RNP es muy rápido ya que solo requiere presentar cada patrón a la red una única ocasión durante el proceso de entrenamiento, a diferencia de las RNPI, la cual requiere la realimentación de los errores y el ajuste de los pesos sinápticos, así como presentar muchas ocasiones los patrones de entrenamiento [2], [8]. Algunas variaciones de las RNP se pueden utilizar para mapeo, clasificación y memoria asociativa. La mayor desventaja de la RNP es el tamaño ya que requiere más espacio de memoria para almacenar el modelo.

La estructura general de las RNP (Figura 2.14), se compone de 4 capas: la primera es la capa de entrada. Las neuronas de entrada no realizan cálculo alguno, sino que simplemente distribuyen la entrada a las neuronas en la primera capa oculta (capa de patrones). Existe una neurona en la capa de entrada para cada variable de predicción. [43], [48], [67]–[69]

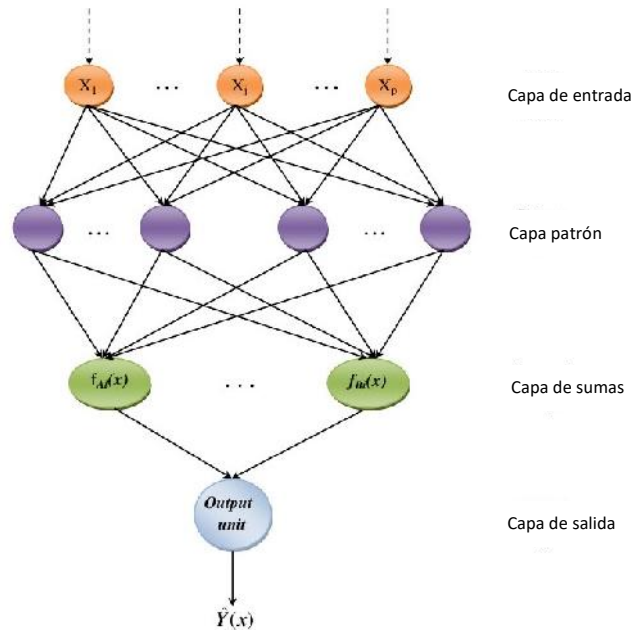


Figura 2.14. Diagrama de bloques de una RNP

La segunda capa es la capa de patrones. Cada neurona patrón representa información en una muestra de entrenamiento. Cada neurona patrón calcula la probabilidad de qué tan bien ajusta el vector de entrada en la neurona patrón. Las neuronas de la capa de patrones se dividen en K grupos, uno para cada categoría. La i -ésima neurona patrón en el k -ésimo grupo calcula su salida empleando un kernel Gaussiano con la forma:

$$f_A(X) = \frac{1}{(2\pi\sigma^2)^{p/2}} e^{-\frac{(X-X_A)^T - (X-X_A)}{2\sigma^2}} \quad (11)$$

Donde:

i es el número patrón

p denota la dimensión del vector de patrones x

σ es el parámetro suavizado del kernel gaussiano

X_A es el centro del kernel.

La tercera capa es la capa de sumatoria. En la capa de sumatoria, existe una neurona patrón para cada categoría de la variable objetivo. Las neuronas de esta capa calculan la aproximación de la función de probabilidad de clase condicional a través de una combinación de las densidades previamente calculadas a través de la siguiente ecuación:

$$f_A(X) = \frac{1}{(2\pi\sigma^2)^{p/2}} \frac{1}{M} \sum_{i=1}^M e^{-\frac{(X-X_A)^T - (X-X_A)}{2\sigma^2}} \quad (12)$$

La cuarta capa es la capa de salida (también llamada capa de decisión). En la capa de salida, se tiene un umbral de difícil limitación (+1) cuando un patrón de entrada X pertenezca a la categoría (A), y (-1) si es de la categoría (B).

El uso de las RNP es especialmente ventajoso debido a su capacidad de converger a la función subyacente de los datos con solamente unos pocos ejemplos de entrenamiento disponibles. El conocimiento adicional necesario para obtener el ajuste de forma satisfactoria es relativamente pequeño y se puede realizar sin la necesidad de datos adicionales por parte del diseñador. Las RNARG caen dentro de la categoría de las RNP. Este tipo de arquitectura de RNA al igual que otros tipos de RNA únicamente necesitan una fracción de las muestras de entrenamiento que podrían requerir las RNAPAPI, debido principalmente a que los datos disponibles para una red de este tipo generalmente nunca son suficientes y en el caso de la espectrometría y dosimetría de neutrones, se cuenta con información limitada siendo la compilación de espectros de neutrones, realizada por la IAEA prácticamente la única fuente de información [71], [72], que para las arquitecturas de RNAPAPI resulta ser insuficiente. Lo anterior hace de las RNARG una herramienta poderosa en tareas de comparación o clasificación, como es el caso de la espectrometría y dosimetría neutrónicas.

2.3.3. Redes neuronales de regresión generalizada

La Red Neuronal Artificial de Regresión Generalizada (RNARG) es un tipo de RNA de propagación inversa supervisada y es una de las redes más populares. Donald F. Specht presentó este tipo de arquitectura en 1991. La RNARG de Specht está relacionada con el clasificador asociado con las RNP. Al igual que las RNP, las RNARG son conocidas por su habilidad de drenar rápidamente en conjuntos de datos dispersos. En lugar de categorizar datos con valores de 0 y 1, como es el caso de las RNP, las RNARG son capaces de producir salidas con valores continuos. Otro punto a favor de este tipo de RNA es que el entrenamiento es muy rápido debido a que los datos solo requieren propagarse hacia delante una vez, a diferencia de las RNAPAPI, en donde los datos deben propagarse muchas veces hacia delante y hacia atrás hasta que se encuentre un valor de error aceptable. [14], [43], [48], [67], [69]

Las RNARG trabajan bien en problemas de interpolación. Sin embargo, debido a que son aproximadores de funciones, tienden a intercambiar la velocidad por la precisión. Este tipo de arquitecturas se utiliza para la estimación de variables continuas, como en las técnicas estándar de regresión. Utiliza un ancho () de función kernel de base radial común el cual se afina hasta alcanzar el óptimo aprendizaje.

La regresión realizada por la RNARG es la expectativa de Y dado $X=x$. En otras palabras, produce el escalar Y más probable dado un vector de entrada x especificado. Sea $f(x,y)$ la función de densidad de probabilidad de unión continua de un vector aleatorio variable X , y un escalar aleatorio variable Y . sea x un valor de medición particular del vector aleatorio X . La regresión de Y dada x (también llamada media condicional de Y dada x) está dada por:

$$E[Y/x] = \int_{-\infty}^{\infty} Y \cdot f(Y/x) d = \frac{\int_{-\infty}^{\infty} Y \cdot f(x,Y) d}{\int_{-\infty}^{\infty} f(x,Y) d} \quad (13)$$

Si la relación entre la variable independiente (X) y la variable dependiente (Y) se expresa en forma funcional con parámetros entonces la regresión será paramétrica. Sin algún conocimiento real de la forma funcional entre x y y , se usará el método de

estimación no paramétrica. Para un estimado no paramétrico de $f(x,y)$, se utiliza uno de los estimadores consistentes que es la función Gaussiana. Este estimador es una buena elección para estimar la función de densidad de probabilidad f , si se puede asumir que la densidad fundamental es continua y que la primera derivada parcial de la función evaluada en cualquier x es pequeña. La buena elección del estimador de probabilidad $\hat{f}(x, y)$ basado en los valores muestra x_i e y_i de las variables aleatorias X e Y está dada por:

$$\hat{f}(x, y) = \frac{1}{(2\pi)^{(p+1)/2} \cdot \sigma^{p+1}} \cdot \frac{1}{n} \sum_{i=1}^n \left\{ e^{-\frac{(X-X_i)^T(X-X_i)}{2\sigma^2}} \cdot \left[\frac{(Y-Y_i)^2}{2\sigma^2} \right] \right\} \quad (14)$$

Donde:

p es la dimensión del vector variable (x).

n es el número de pares de entrenamiento ($x_i \rightarrow y_i$)

σ es el único parámetro (valor de suavizado) elegido durante el entrenamiento de la red

Y_i es la salida escalar deseada dada el valor x_i observado




Figura 2.15. Arquitectura básica de la RNARG

La topología de la RNARG presentada en la Figura 2.15, está compuesta de cuatro capas: la primera capa es la capa de entrada, totalmente conectada con la segunda capa. Las neuronas de entrada son simplemente unidades de distribución, que proporcionan todas las variables de medición X a todas las neuronas de la segunda capa, las unidades de patrón. La segunda capa es la primera capa oculta (también llamada capa patrón). Esta capa está compuesta de N neuronas de procesamiento, en donde N es el número de muestras dentro del conjunto de datos de entrenamiento y cada neurona representa el vector de entrada X_i , asociado a partir del vector asignado con la j -ésima muestra en los datos de entrenamiento. En cada neurona, se resta cada vector de entrada del vector asignado al nodo X_j . Esta diferencia es elevada al cuadrado por la neurona. El resultado se alimenta a un núcleo no lineal, que generalmente es una función exponencial. Las salidas de las neuronas patrón se pasan a las neuronas de sumatoria.

Nótese que la segunda capa oculta siempre tiene exactamente una neurona más que la capa de salida. Cuando se necesita una salida (vector) multidimensional, el único cambio a la red es añadir también una neurona adicional a la segunda capa oculta, más una neurona adicional en la capa de salida para cada elemento del vector de salida.

La tercera capa es la segunda capa oculta (la capa de sumatoria) la cual tiene dos neuronas también. La entrada a la primer neurona es la suma de la primer capa oculta, cada una ponderada por la salida observada Y_j correspondiente a X_j . La entrada de la segunda neurona es la sumatoria de las activaciones de la primera capa oculta.

La cuarta capa es la capa de salida. Recibe las dos salidas de la capa oculta y las divide para producir un estimado de Y (o para proporcionar los resultados de la predicción).

En las arquitecturas de RNARG a diferencia de otro tipo de arquitecturas como la RNAPAPI no se requiere optimizar parámetros de entrenamiento como la tasa de aprendizaje y el momento, sin embargo, se aplica un factor de suavizado (λ), el cual se aplica después de entrenar a la RNA. La elección de este factor de suavizado del kernel (λ) es muy importante, ya que tiene el efecto de suavizar los ejemplos de entrenamiento. Valores pequeños de (λ) tienden a hacer distinto cada punto de entrenamiento, mientras que valores grandes forzarán un mayor grado de interpolación entre las observaciones de entrenamiento. Para las RNARG, el factor de suavizado debe ser mayor a 0 (cero) y puede estar generalmente en el rango de 0.01 a 1 con buenos resultados. Es necesario realizar varios experimentos para determinar qué factor de suavizado es el más apropiado para los datos que se están utilizando para entrenar la RNARG. [30]

Un método útil para seleccionar el valor de (λ) es el método Holdout. Para un valor particular de (λ), el método Holdout consiste en quitar una muestra a la vez y construir una red basada en todas las otras muestras. Entonces se utiliza la red para estimar Y para la muestra que se quitó. Al repetir este proceso para cada muestra y almacenar cada estimado, se puede medir el error medio cuadrático (MSE) entre los valores actual Y_i y los estimados. Se debería utilizar el valor de (λ) que proporcione el error más pequeño en la RNARG. [43]

Afortunadamente, en la mayoría de las aplicaciones existe un valor único de (λ) el valor mínimo de MSE entre la salida de la red y la salida deseada para el conjunto de datos de prueba que se puede encontrar a través del ensayo y el error.

Como se ha mencionado, la teoría de RNA ha brindado una alternativa a las técnicas clásicas de cómputo para aquellos problemas en los que los métodos tradicionales han entregado resultados no muy convincentes o poco convenientes. Este es el caso del área de investigación que busca resolver los problemas relacionados con la espectrometría y dosimetría neutrónica por medio del SEEB. En el presente proyecto de investigación se estudia y explora el uso de *redes neuronales artificiales de*

regresión generalizada como una alternativa a los problemas intrínsecos a este dominio de conocimiento, los cuales se exponen a continuación.

2.4. Espectrometría de neutrones por medio de redes neuronales de regresión generalizada

2.4.1. Los neutrones

2.4.1.1. Introducción

El conocimiento de la física del átomo y su núcleo comenzaron con el descubrimiento de la radiactividad por H. Becquerel en 1896, quien descubrió la radiactividad al intentar establecer una relación entre la radiación solar y la propiedad de velar placas fotográficas de sales de U (Uranio), mismas que tenían la capacidad de velar las placas aún a pesar de no recibir luz solar. Lo anterior motivó a M. Curie en 1898, a investigar cuál era la causa de la emisión de energía del U, llegando a identificar un nuevo elemento, el Ra (Radio), que emitía una radiación altamente penetrante, así como el demostrar que la tasa de emisión no se modificaba por cambios físicos o químicos, es decir, cualquier cambio en la presión, volumen, temperatura o forma química, no cambian el porcentaje de emisión de la radiación. [17]

E. Rutherford y F. Soddy en 1902 sugirieron que la radiactividad se debía a la desintegración espontánea de los átomos, y que los nuevos elementos entonces formados, podrían tener propiedades totalmente diferentes con relación a las de los elementos iniciales. No obstante que la desintegración del átomo es un proceso espontáneo, la actividad es un proceso prolongado que se puede extender por períodos que van desde algunos segundos hasta millones de años. [73]

Después del descubrimiento de la radiactividad, muchos esfuerzos se dirigieron a estudiar las propiedades de esta radiación, especialmente las que se relacionaban con

el poder de penetración en diferentes materiales, la ionización específica en distintos gases y el comportamiento sobre los efectos de un campo magnético y eléctrico. Como se aprecia en la Figura 2.16, las radiaciones de sustancias radiactivas naturales, se clasificaron en componentes de acuerdo con su poder de penetración. [74]

Al observar la Figura 2.16, se aprecia que un primer tipo de radiación con un poder de penetración sumamente débil, es detenido por una hoja de papel ordinario, pero causaba una ionización intensa en el aire, éstos son los rayos α (rayos alfa o protones); un segundo tipo de radiación tiene menor poder de ionización, pero mayor poder de penetración que los rayos α , y puede pasar fácilmente a través de delgadas láminas de metal (de algunos milímetros de espesor), conocidos como rayos β (rayos beta, electrones o positrones); el tercer tipo causa aún menos ionización pero tiene la capacidad de penetrar planchas de diversos materiales de varios centímetros de espesor, denominados rayos γ (rayos gama o fotones).




Figura 2.16. Poder de penetración de partículas radiactivas

En 1920 E. Rutherford sugirió que podía existir una partícula neutra, posiblemente un protón y un electrón estrechamente ligados, al que denominó neutrón. En 1930 los físicos alemanes W. Bothe y H. Becker produjeron una radiación fuertemente penetrante bombardeando núcleos de ${}^9\text{Be}$ con partículas α de 5.3 MeV procedentes de una fuente radiactiva, encontrando que muchos núcleos se transformaban en radiactivos y emitían lo que se pensaba eran rayos γ , ya que la radiación podía penetrar fácilmente varios centímetros de Pb (Plomo) y no era desviada por campos eléctricos y magnéticos como se muestra en la Figura 2.17, se supuso que consistía de rayos altamente energéticos. [75], [76]




Figura 2.17. Comportamiento de partículas radiactivas ante campos magnéticos

En 1932, James Chadwick, trabajando en el laboratorio Cavendish, sugirió que la radiación desconocida no constaba de rayos γ en absoluto, sino de una partícula sin carga (el neutrón), aproximadamente del mismo tamaño que el protón, tal y como lo había sugerido Rutherford 12 años antes. [77], [78]

2.4.1.2. El descubrimiento del neutrón

Desde su descubrimiento por Chadwick, el neutrón ha jugado un rol significativo en el entendimiento de la estructura del núcleo. Debido a que los neutrones no son desviados por un campo eléctrico o magnético, y también porque no producen una ionización apreciable, se deben emplear métodos indirectos para detectarlos y medir su energía. [23], [79]

El descubrimiento del neutrón se realizó en 1932, período en el que grupos de investigación alrededor del mundo estudiaron los efectos del bombardeo de partículas sobre blancos de elementos ligeros como el Li (Litio), Bo (Boro) y Be (Berilio) [80]. Este bombardeo producía una irradiación secundaria altamente penetrante, que al atravesar un medio hidrogenado, originaba que varios núcleos de H (Hidrógeno) salieran lanzados a grandes velocidades.

En 1930 W. Bothe y H. Becker reportaron que al bombardear Be con partículas emitidas por Po (Polonio), se producía una radiación altamente penetrante. En un

principio supusieron que se trataba de rayos γ , sin embargo, tenía un fuerte poder de penetración en el Pb. En 1932, utilizando una cámara de Wilson, Chadwick demostró que la radiación desconocida era capaz de lanzar a grandes velocidades no solamente protones, sino también núcleos más pesados como: He, Li, Be, B, C, N, O y Ar. De lo obtenido por esta cámara, Chadwick pudo medir la energía cinética de los núcleos lanzados, deduciendo la masa de estas partículas misteriosas. Admitiendo que la masa de la partícula misteriosa era de 1 u.m.a. y que su carga era nula, llegó a la conclusión de que la masa de esta partícula a la que llamo “neutrón” era prácticamente la misma que la del protón. [80]

El descubrimiento del neutrón ha sido de importancia primordial. La ausencia de carga eléctrica le confiere un elevado poder de penetración y la posibilidad de interactuar con la materia de manera distinta a la de las partículas cargadas y radiación electromagnética. Dadas las dimensiones ocupadas por los núcleos, estas interacciones tienen una pequeña probabilidad (sección eficaz) y producen, excepto casos particulares, una escasa pérdida de energía, lo que conduce a que sea necesario un gran número de colisiones para que la energía del neutrón disminuya de manera significativa. Esta circunstancia hace que los neutrones juntamente con la radiación γ , sean mucho más penetrantes que las partículas cargadas y puedan de esta forma atravesar espesores importantes de materia, como se aprecia en la Figura 2.16.

2.4.1.3. Clasificación y propiedades de los neutrones

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, si bien los límites que definen esta clasificación aún están sujetos a discusión, los neutrones se clasifican de acuerdo a su energía, ya que el tipo de reacción que sufre el neutrón depende directamente de ésta. El Tabla 2.2 muestra una clasificación aceptada de los neutrones atendiendo a su energía. [80], [81]

Tabla 2.2. Clasificación de los neutrones

Neutrones	Rango de energías
Térmicos	< 0.4 eV
Intermedios	0.4 eV - 10 keV
Rápidos	10 keV - 10 MeV
Relativistas	> 10 MeV

Los neutrones térmicos son aquellos que se encuentran en equilibrio térmico con los núcleos del medio donde se encuentran, se les puede aplicar las nociones de la teoría cinética de los gases y su distribución sigue la estadística de Maxwell–Boltzman; los neutrones intermedios resultan de la colisión elástica de los neutrones rápidos en materiales de bajo número atómico, la distribución de estos neutrones es proporcional al inverso de su velocidad; los neutrones rápidos son aquellos que tienen una energía superior a unas decenas de keV, valor utilizado como límite por debajo del cual los instrumentos para la detección de estos neutrones resultan inadecuados; finalmente, se consideran relativistas todos los neutrones cuya energía es superior a los 10 MeV. [82]

2.4.1.4. Producción de neutrones

Para investigar un campo de neutrones desde un punto de vista espectrométrico y dosimétrico, el conocimiento de su origen y producción de los mismos es una información a priori importante para la elección del tipo de instrumento de medida a utilizar y el análisis de los resultados de la medida.

Existen varias maneras de producir neutrones, entre los más importantes están: la fisión espontánea, como en el caso de la fuente de Cf – 252 (California); las reacciones (α, n) , como las fuentes isotópicas de $^{241}\text{AmBe}$ (Americio-Berilio) y ^{241}AmB (Americio-Boro); las reacciones (γ, n) , como las fuentes foto neutrónicas que utilizan como núcleos destino el Be^9 o el ^2H (deuterio); los aceleradores de partículas mediante reacciones del tipo (p, n) , $(^2\text{H}, n)$ y (α, n) o de astillado sobre núcleos pesados; también se podría mencionar a los neutrones producidos en los aceleradores de electrones,

donde los fotones secundarios altamente energéticos inducen reacciones del tipo (γ, n) , $(\gamma, p-n)$ y $(\gamma, -n)$.

Los neutrones obtenidos por la mayoría de las fuentes presentan una distribución energética bastante amplia, tal como se ilustra en la Figura 2.18, en donde se muestran espectros de neutrones producidos por fuentes del tipo (γ, n) , la excepción a esta situación se da en los aceleradores donde para ciertas reacciones se producen neutrones monoenergéticos. No obstante, es posible obtener haces casi monoenergéticos a partir de espectros neutrónicos amplios utilizando adecuadas combinaciones de filtros.

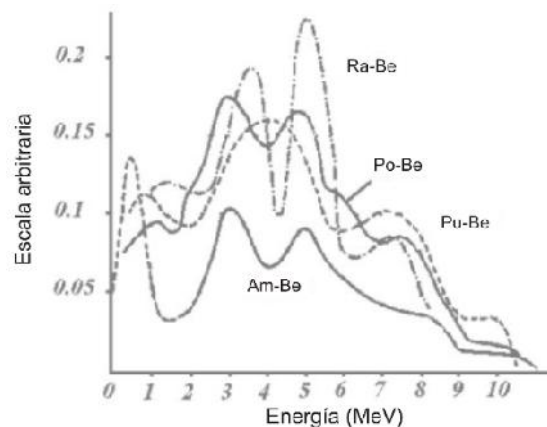


Figura 2.18. Espectro de los neutrones del $^{241}\text{AmBe}$, $^{239}\text{PuBe}$, $^{226}\text{RaBe}$ $^{210}\text{PoBe}$

La distribución espectral de neutrones en el momento de su producción se modifica enormemente cuando atraviesan materiales diversos. La forma de los espectros encontrados con mayor frecuencia en el dominio de la radioprotección se encuentra en las publicaciones 180 y 318 de la OIEA. [71], [72]

2.4.1.5. Interacción de los neutrones con la materia y el tejido

La interacción de los neutrones con la materia es un proceso bastante diferente al de las partículas cargadas y la radiación electromagnética. Dado que los neutrones no poseen carga eléctrica, no pueden ionizar directamente la materia que atraviesan y

por lo tanto su interacción es únicamente con los núcleos de los átomos. Las interacciones más comunes del neutrón con la materia son colisiones inelásticas, captura elástica y fisión. Un núcleo que colisiona inelásticamente con un neutrón queda en un nivel de energía más alto, entonces puede liberar esta energía emitiendo fotones, mediante la emisión de una partícula o de ambas formas. [31]

En la captura de neutrones, un núcleo afectado puede absorber el neutrón y expulsar energía en forma de rayos γ , rayos X, partículas α , partículas β o todas estas. Las partículas secundarias causan después ionización; en la fisión, un núcleo pesado puede absorber al neutrón y después de pasar por el estado del núcleo compuesto dividirse en dos núcleos más ligeros que casi siempre son radiactivos.

La materia orgánica está compuesta esencialmente de elementos de bajo número másico como el H, O, N y C. Estos elementos son buenos moderadores de neutrones. Los neutrones térmicos e intermedios depositan esencialmente casi toda la energía en el tejido mediante colisiones inelásticas que los moderan y termalizan; y en este estado sufren la captura neutrónica los núcleos de H y N. La captura $^1\text{H}(n, \gamma)^2\text{H}$, produce un fotón por energía del orden de 2.2 MeV. Estos γ , interaccionan a su vez con el tejido por efecto fotoeléctrico, Compton o producción de pares [79], [83], produciendo electrones que son los responsables de las ionizaciones producidas a lo largo de su recorrido. Estos rayos γ son la mayor contribución a la dosis en el cuerpo para neutrones de energía inferiores a 200 keV.

La otra reacción de captura $^{14}\text{N}(n,p)^{14}\text{C}$, da lugar a la emisión de protones de 0.62 MeV. En este caso tanto los protones como los núcleos de retroceso al ser partículas cargadas, son los responsables de las ionizaciones producidas a lo largo de su recorrido. Esta reacción es importante en el cálculo de la dosis equivalente para energías inferiores a 100 keV.

Los neutrones rápidos ceden principalmente su energía al tejido mediante la dispersión elástica. En efecto, durante una colisión con el núcleo de H, el neutrón puede perder en promedio la mitad de su energía y la cede a los protones de H que al reular producen ionización, pudiendo los núcleos de H ser liberados. Mediante este proceso, un neutrón de 1 MeV, puede sufrir cerca de 20 colisiones para termalizarse, lo que equivaldría a un recorrido de unos 5 cm en el tejido.

El neutrón termalizado es, o bien capturado por uno de los procesos citados anteriormente, o en otros casos puede ser dispersado fuera del cuerpo humano dando lugar a los neutrones albedo. [79]

Los neutrones rápidos también colisionan con los demás constituyentes del tejido, pero la pérdida de energía es relativamente pequeña comparada con el H, como lo prueba el hecho de que los neutrones con energías comprendidas entre 0.5 y 5 MeV pierden el 90 % de su energía en colisiones con los núcleos de H [84]. La Figura 2.19, muestra el conjunto de reacciones con el tejido que contribuyen a la dosis en función de la energía del neutrón [49].




Figura 2.19. Interacción de los neutrones con el tejido

Con el descubrimiento de la radiactividad, muchos esfuerzos se han dirigido a estudiar los efectos nocivos de la radiación ionizante y no ionizante, especialmente con relación a los neutrones, dada sus propiedades intrínsecas. La detección de neutrones es un problema mucho más complejo que la detección de partículas cargadas y fotones, ya que los neutrones no transportan ninguna carga eléctrica y no causan ionización directa, aunque su poder de penetración ocasiona un mayor daño al personal que se ve expuesto a ellos.

2.5. Dosimetría de campos neutrónicos

2.5.1. Protección radiológica

La protección radiológica es el área de la ingeniería de la salud ambiental que trata de la protección del individuo y grupos de personas contra los efectos detrimentales de la radiación ionizante y no ionizante. La protección radiológica es responsable de los aspectos de seguridad en el diseño de procesos, equipos e instalaciones que utilizan fuentes de radiación, para que la exposición del personal sea mínima y para que, en todo tiempo, la radiación esté dentro de los límites aceptables. Esta disciplina debe mantener al personal y al entorno bajo constante supervisión, para cerciorarse de que el uso y almacenamiento de las fuentes de radiación se hagan en condiciones seguras.

Si se encuentra que las medidas de control no son efectivas o que han fallado, la seguridad radiológica debe ser capaz de evaluar el grado de riesgo y realizar las recomendaciones pertinentes tendientes a tomar acciones correctivas. Los aspectos científicos y de ingeniería en los que la seguridad radiológica interviene, incluyen las mediciones físicas de diferentes tipos de radiación y materiales radiactivos, el establecimiento de relaciones cuantitativas entre la exposición a la radiación y el daño biológico, el transporte de la radiactividad en el medio ambiente y el diseño de equipo radiológico, procesos y entornos seguros.

Con base en lo anterior, las mediciones de la fluencia de dosis han llegado a ser el factor determinante que obligan a establecer procedimientos, prácticas y entornos de trabajo que limiten la exposición a la radiación. [79]

2.5.2. Espectrometría y dosimetría de neutrones

Con el descubrimiento de la radiactividad, muchos esfuerzos se han dirigido a estudiar las propiedades de la radiación. La detección de neutrones es un problema mucho más complejo que la detección de partículas cargadas y fotones, ya que los neutrones no transportan ninguna carga eléctrica y no causan ionización directa.

Desde el descubrimiento de los neutrones por Chadwick en 1932, se han desarrollado diversos métodos para medir la distribución de energía de los neutrones, también llamada espectro [79]. El objetivo de la espectrometría y dosimetría de neutrones en la protección radiológica, es proporcionar un método para valorar la magnitud de los efectos detrimentales en la salud debida a la exposición de radiación de neutrones. El logro satisfactorio de esta meta requiere alcanzar dos objetivos separados: el primero es identificar una cantidad que sea una medición razonablemente exacta del daño biológico ocasionado por la irradiación de neutrones, y el segundo es encontrar métodos, de preferencia simples, para la apropiada medición de esta cantidad en entornos de trabajo.

La espectrometría neutrónica ha contribuido de forma importante al desarrollo de la física nuclear y es un importante instrumento en otros campos tales como la tecnología nuclear, fusión nuclear, radioterapia y radioprotección. Los métodos utilizados en espectrometría neutrónica se pueden clasificar atendiendo al principio utilizado para caracterizar o medir la energía del neutrón [20]. De entre todos éstos destacan por su importancia y grado de utilización los basados en: la medida de la energía de los núcleos que reulan al interactuar con los neutrones, la medida de las energías de las partículas cargadas creadas en reacciones nucleares producidas por neutrones, la medida de la velocidad del neutrón, la medida de la radiactividad (una específica

emisión o transición de fase) inducidas en ciertas reacciones producidas por los neutrones y denominadas de umbral, y finalmente en métodos en los que la distribución energética de fluencia se obtiene por deconvolución de un conjunto de medidas realizadas con ciertos detectores y geometrías.

2.5.3. Evolución de la espectrometría neutrónica

Cuatro fases bien diferenciadas se ponen de manifiesto en la evolución de la espectrometría de neutrones. Las dos primeras corresponden a los períodos comprendidos entre 1932-1959 y 1960-1979 respectivamente [73], [85]. Muchos de los espectrómetros de neutrones utilizados actualmente se basan en métodos utilizados antes de 1960. Así, en los espectrómetros denominados de retroceso de esta época, se utilizaban cámaras de ionización y contadores proporcionales, emulsiones nucleares, centelladores orgánicos [86]. En los basados en la medida de las energías de las partículas cargadas creadas, contadores proporcionales de ^3He [87], centelladores de ^6LiI (Eu) [88]. Espectrómetros basados en la medida del tiempo de vuelo de los neutrones y en reacciones de activación [86], fueron también muy utilizados durante este período.

Un notable desarrollo se produce durante la segunda fase (1960-1979), con la introducción del método basado en el Sistema Espectrométrico de Esferas Bonner (SEEB) [23] y los avances conseguidos en las técnicas de espectrometría neutrónica utilizando detectores de gas [89] y de centelleo [90]. En este período también supuso un importante desarrollo la aparición de los primeros códigos de deconvolución de espectros neutrónicos, obtenidos a partir de medidas realizadas con multicanales, así como la utilización por primera vez de los semiconductores en la espectrometría neutrónica [87] y la introducción de los detectores de burbujas [91].

La tercera fase a partir del año 1979, se caracteriza por un gran avance tecnológico y el gran progreso que significó la incorporación de computadoras más potentes, que permitieron por medio de métodos Monte Carlo, el cálculo de las funciones de

respuesta y eficiencias de detección de los detectores utilizados, así como una mejora en los programas de deconvolución, para obtener espectros neutrónicos a partir de las lecturas realizadas con los espectrómetros [92]. Cabe mencionar que los códigos de deconvolución utilizados, y por tanto los métodos utilizados para su ejecución, están basados en métodos que contienen un determinado algoritmo de cálculo que el usuario debe conocer con precisión, ésto representa una seria desventaja en el uso de estas herramientas.

Con el avance de la ciencia moderna, en la cuarta y última fase desarrollándose en la época actual, se están utilizando técnicas alternativas basadas en la máxima entropía [34] y en tecnologías de IA para realizar la espectrometría y dosimetría de neutrones. Entre las principales técnicas por medio de IA, se pueden mencionar los AG [93] y las RNA, destacándose el uso de estas últimas [34], [44], [94]–[98].

Entre todas las técnicas disponibles para la espectrometría de neutrones, el SEEB ha sido el más utilizado para los propósitos de la protección radiológica [19], debido a sus características, como son el amplio rango de energías, de térmicos a varios GeV, la gran variedad de sensores térmicos, pasivos o activos, que se pueden utilizar lo que permite adaptar la sensibilidad al espacio de trabajo específico, entre otras [31].

2.5.4. Espectrometría de neutrones a partir del SEEB

En 1960 R.L. Bramblett, R.I. Ewing y T.W. Bonner describieron un espectrómetro de neutrones hecho con un detector de neutrones térmicos cubierto con esferas de polietileno [23], Figura 2.20. Como se observa en la Figura 2.21, en principio, a medida que los neutrones atraviesan las esferas de polietileno, se dispersan los neutrones rápidos y epitérmicos perdiendo energía hasta que alcanzan el balance térmico o salen del moderador. El detector responde a los neutrones térmicos que llegan al centro de la esfera moderadora [86].




Figura 2.20. Espectrómetro de neutrones de Bonner




Figura 2.21. Detección de neutrones con el SEEB

Como se observa en la Figura 2.22, la combinación detector-moderador tendrá una respuesta diferente a los neutrones en función de la energía. A partir de las tasas de conteo tomadas con las esferas, es posible reconstruir el espectro de neutrones, éste proporciona información acerca de la distribución de energía de los neutrones incidentes. En el SEEB, cada detector se caracteriza por una función de respuesta. A medida que se incrementa el tamaño del moderador, el pico de la función de respuesta cambia hacia neutrones de energía mayor.




Figura 2.22. Matriz de respuesta del SEEB de la UAEN-UAZ

Cuando se utiliza el SEEB, se miden las tasas de conteo que los neutrones producen en cada uno de los detectores del sistema [45], [99]. Cuando 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 [100]. El incrementar el diámetro de las esferas permite que se puedan detectar neutrones de energías mayores a las térmicas. 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 $\theta(E)$, se muestran en la ecuación 16 [45], [99].

$$C(D) = \int_{E_m}^{E_m} R(D,E)\theta(E)dE \quad (16)$$

Esta es la ecuación integro-diferencial de Fredholm de primer tipo, que en su versión discreta se indica en la ecuación 17.

$$C_j = \sum_{i=1}^m R_{i,j}\theta_i \quad (17)$$

Donde 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, θ_i es la fluencia de

neutrones en el i -ésimo intervalo de energía y m es el número de esferas del sistema espectrométrico.

Debido a que el número de detectores (esferas) es menor que el número de grupos de energía usados para describir el espectro, la ecuación 17 se convierte en un sistema de ecuaciones mal condicionado, en estos casos no existe una solución única, se tiene un número infinito de soluciones; el seleccionar aquella que tenga significado para el tipo de problema es parte del proceso de reconstrucción, por lo que se debe aplicar algún procedimiento para la deconvolución del espectro. Existen varios métodos para resolver el problema de la reconstrucción de los espectros de neutrones y la mayoría de ellos, excepto aquellos que se basan en los métodos Monte Carlo [26], [29], RNA [45], [97], [98], AG o una combinación de estas últimas, utilizan algoritmos iterativos.

2.6. Códigos y técnicas de deconvolución

Para poder obtener mediante un proceso de deconvolución los espectros neutrónicos a partir de las medidas realizadas con un SEEB convenientemente calibrado, es necesario conocer las respuestas de cada una de estas esferas en función de la energía del neutrón. La indicación de una esfera Bonner se expresa por el producto de la convolución de su respuesta en función de la energía $R(E)$, por la tasa de fluencia energética de los neutrones en el punto de medida $\Phi(E)$ como se describe en la ecuación 16. Una vez fijadas las condiciones de calibración del SEEB, así como la validación de las funciones de respuesta del mismo, la determinación del espectro neutrónico resuelve el sistema de ecuaciones descrito en la ecuación 17.

La deconvolución del espectro neutrónico medido, consiste en establecer la tasa de distribución energética de fluencia $\Phi(E)$, la matriz de respuesta $R(E)$ y el conjunto de medidas realizadas Mdr . Para $m=n$, el sistema de ecuaciones admite una solución exacta, si bien esta solución es raramente aceptable, las incertidumbres experimentales de los recuentos Mdr y los inevitables asociados a la matriz de

respuesta suelen dificultar obtener un resultado satisfactorio. Si $m > n$, el sistema de ecuaciones es sobredeterminado y la solución se puede obtener por una técnica de regresión. No obstante, y dado que el número de grupos de energías es pequeño, se consigue una pobre resolución energética. Si $m < n$, que es el caso más frecuente, el sistema es indeterminado, difícil de tratar y admite infinitas soluciones de las cuales es necesario encontrar aquella que represente adecuadamente el espectro medido.

2.6.1. El problema de la reconstrucción

La reconstrucción de espectros de neutrones utilizando datos obtenidos a partir de laminillas de activación, esferas Bonner u otros detectores, generalmente implica resolver la ecuación 16 o 17.

Aunque existen varios métodos para la solución formal de las ecuaciones integrales de primer orden, ninguno de esos métodos es generalmente aplicable cuando la función de respuesta del detector $R_{i,j}$ no se conoce analíticamente y al hecho de que la cantidad de detectores que se usan es siempre finito. Este es el caso de todos los sistemas prácticos utilizados para la espectrometría de neutrones. En la práctica, $R_{i,j}$ se calcula o se determina experimentalmente y es generalmente aproximado por una matriz de respuesta con valores discretos. La ecuación 16 se reemplaza entonces por un conjunto de ecuaciones lineales, pero persiste el problema de resolver m ecuaciones con n incógnitas, en donde m es el número de detectores disponibles y n es el número de grupos de energía con que se define el espectro de neutrones. Lo anterior se podría expresar en notación matricial como se indica a continuación:

$$\bar{Y} = A * \bar{\theta} \quad (18)$$

Donde ahora \bar{Y} y $\bar{\theta}$ son vectores y A es una matriz de $m \times n$. Generalmente n es mayor que m , de aquí que no exista una solución única, ya que se forma un sistema de ecuaciones mal condicionado que tiene un número infinito de soluciones, éstas pueden tener amplias oscilaciones, algunas veces negativas, soluciones que tienen muy poco

significado físico. Lo anterior conduce a introducir los términos “exacto”, “aproximado” y “apropiado” para caracterizar las soluciones de la ecuación 18. Una solución exacta, si existe alguna, satisface exactamente la ecuación, pero podría ser negativa u oscilatoria. Las soluciones aproximadas satisfacen la ecuación únicamente dentro de límites de error razonables. De las soluciones aproximadas, la selección de la solución más aceptable físicamente hablando produce una solución apropiada.

2.6.2. Métodos y códigos utilizados para la deconvolución

De acuerdo con el trabajo realizado por Matzke [100], la determinación de la fluencia de partículas espectrales a través de la reconstrucción de las lecturas de los detectores medidos ha sido investigada por muchos autores y se han desarrollado diversos métodos para resolver el problema de la detección de neutrones y la determinación del espectro. La parte más delicada de la espectrometría basada en el SEEB, es el proceso de reconstrucción. La deconvolución del espectro neutrónico medido consiste en establecer la tasa de distribución energética de fluencia $R_{i,j}$ conocida como la matriz de respuesta y el conjunto de medidas realizadas C_j , (ecuación 17), para lo cual es necesario aplicar métodos de reconstrucción. Durante los últimos años se han logrado importantes progresos en el desarrollo de métodos y códigos en un intento por resolver los problemas de la reconstrucción del espectro de neutrones y el cálculo de dosis equivalentes.

En la dosimetría de reactores para la reconstrucción de algunos canales se utilizaron con éxito códigos basados en métodos de mínimos cuadrados lineales. Los códigos STAY'SL, LEPRICON, LSL, DIFBAS, DIFMAZ, pertenecientes al paquete de programas HEPRO, y los códigos MSITER y MINCHI son ejemplos representativos de un gran número de códigos basados en métodos de ajuste de mínimos cuadrados, mismos que también se han aplicado con éxito para la reconstrucción de datos medidos a través del SEEB.

Un segundo grupo de códigos que excluyen valores negativos de fluencia son: SAND I y II, GRAVEL [101] (basado en algoritmo mejorado de SAND II), LSL-M2, LOHUI, BUNKI [92], RADAK. Estos códigos en principio, realizan un ajuste no lineal por medio de mínimos cuadrados, con la restricción de reconstruir únicamente fluencia de partículas no negativas. En este contexto, se tiene que mencionar el método propuesto por Schmittroth, quien utiliza una distribución logarítmica normal de las variables para evitar valores de fluencia negativos. Además, Schmittroth utiliza correlaciones en el espectro a priori como medio para asegurar un suavizado.

Durante los últimos años, se han realizado intentos por desarrollar nuevos códigos de deconvolución de espectros de neutrones, entre los cuales se pueden mencionar: MITOM [24], FRUIT [25], BUMS [102]. Estos códigos están basados en algoritmos de reconstrucción iterativos. Sin embargo, se observa que el uso de éstas herramientas ofrece ciertos inconvenientes, como es la necesidad de proporcionar información inicial a priori, como un “espectro inicial”, mismo que deberá estar tan cerca como sea posible a la solución que se desea obtener y que en la mayoría de los casos es desconocido.

Los puntos críticos de los códigos mencionados son, en general: la complejidad en el uso de éstos y en consecuencia, la necesidad de un usuario muy experto, así como el gran consumo de tiempo en el proceso de reconstrucción del espectro. Dentro de las complejidades mencionadas, el problema más serio que estos programas presentan, es la necesidad de que el usuario proporcione información real a priori, que como se ha mencionado, debe ser lo más cercano posible al espectro que se desea obtener, para poder llevar a cabo la reconstrucción del espectro de forma eficiente, lo que en la práctica resulta ser complicado ya que en la mayoría de las ocasiones se desconoce el espectro que se desea medir.

Las desventajas de los códigos descritos han motivado a los investigadores a buscar nuevas propuestas de reconstrucción. Con la evolución de esta compleja sociedad tecnológica y la introducción de nuevas nociones y herramientas teóricas innovadoras en el campo de los sistemas inteligentes, el campo de la IA está sufriendo una gran

evolución. En las últimas décadas se han intentado procedimientos novedosos para el proceso de reconstrucción de espectros basado en AG [103], RNA [36], [45], [94]–[98], [104], técnicas híbridas de RNA evolucionadas por medio de AG (RNAG) [38], [81] y en el presente proyecto de investigación se estudia y explora el uso de RNARG.

Capítulo 3

Materiales y Métodos

El uso de la tecnología de RNA en Espectrometría y Dosimetría de Neutrones (EDN) presenta retos tecnológicos importantes, ya que por un lado las metodologías de diseño de RNA empleadas actualmente requiere la optimización de múltiples parámetros de diseño y por otro lado, como es una tecnología emergente que está siendo recién aplicada en esta área del conocimiento, no se cuenta con herramientas apropiadas para aplicarlas de forma efectiva. Lo anterior pone de manifiesto que existe la necesidad de desarrollar nuevas metodologías y herramientas científico-tecnológicas que permitan resolver los problemas mencionados.

Para validar la hipótesis establecida en el presente proyecto y alcanzar la meta científica y los objetivos planteados, a continuación se describen los materiales y métodos utilizados. Como se observa en la Figura 3.1, la espectrometría y dosimetría de neutrones empleando la tecnología de RNARG a partir de las tasas de conteo del SEEB se divide en varias etapas: en primer lugar, se realiza una etapa de pre-procesamiento de los datos que conformarán las matrices de entrenamiento de la RNA.

La siguiente etapa implica determinar el valor crítico de la RNARG que será entrenada. Posteriormente se realiza el entrenamiento de la red. Una vez entrenada la RNARG, la misma se encuentra lista para realizar la reconstrucción del espectro de neutrones

y el cálculo de 15 cantidades dosimétricas utilizando como única pieza de información las tasas de conteo provenientes de un SEEB.

El código de deconvolución de espectros de neutrones desarrollado en base a tecnología de RNARG presentado en el presente proyecto de investigación, es capaz de realizar la reconstrucción de espectros de neutrones utilizando las matrices de respuesta contenidas en el compendio de neutrones compilado por la Agencia Internacional de Energía Atómica (IAEA, de sus siglas en inglés).

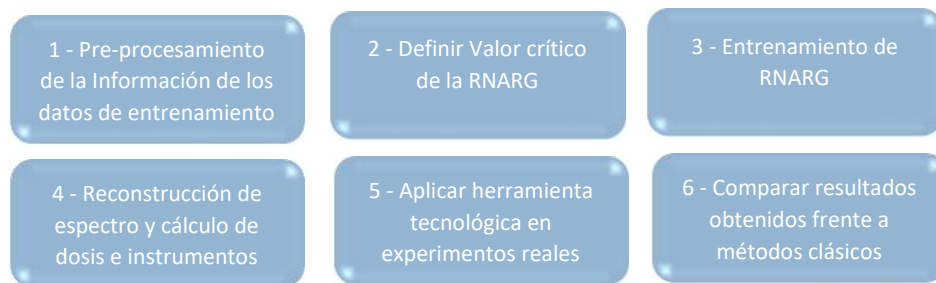


Figura 3.1. Esquema general de RNA aplicadas en la espectrometría neutrónica

3.1. Pre-procesamiento de la información de datos de entrenamiento

En virtud de que las RNARG son redes del tipo propagación hacia adelante con entrenamiento supervisado, se requiere un conjunto de datos tanto de entrada como de salida para realizar el entrenamiento de las mismas. Estos datos se obtuvieron del compendio de la IAEA, dentro de los cuales se encuentran espectros producidos por fuentes isotópicas de neutrones, reactores nucleares, aceleradores de uso médico y de investigación en física, rayos cósmicos, entre otros.

Este compendio contiene una gran colección de respuestas de detectores y espectros de neutrones, así como los coeficientes de conversión de fluencia a dosis de 15 cantidades dosimétricas y varios instrumentos de medición. [72]

La principal motivación para la creación de este reporte fue la necesidad de proporcionar información técnica específica que pudiera ser utilizada por los especialistas en protección radiológica para la selección apropiada de dosímetros e instrumentos de medición, y para la interpretación de datos obtenidos con estos detectores. Los espectros reportados en este compendio están definidos en unidades de letargia y están expresados en 60 grupos de energía que van desde los neutrones térmicos hasta los 630 MeV. En el presente trabajo de investigación, se utilizó un total de 251 espectros de neutrones y 15 cantidades dosimétricas.

La etapa de pre-procesamiento de la información requerida para realizar el entrenamiento de las RNARG implicó realizar lo siguiente;

1. Extraer 251 espectros de neutrones del compendio IAEA. Este compendio se puede descargar en formato PDF. De este archivo se extrajo la información correspondiente a cada uno de los 251 espectros de neutrones. En la Figura 3.2 se muestra la gráfica con el conjunto de espectros.

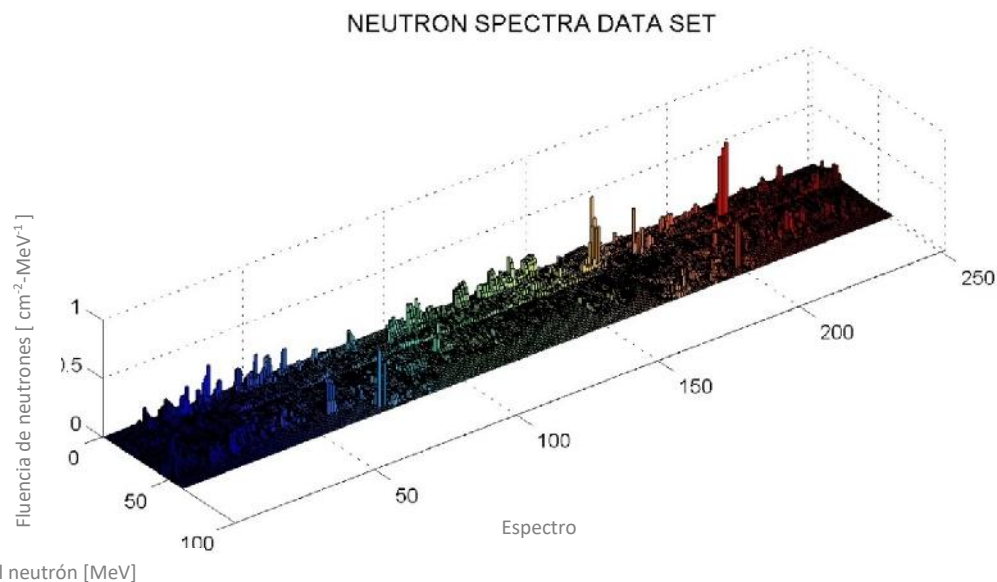


Figura 3.2. 251 espectros de neutrones utilizados en el entrenamiento de RNARG

2. Extraer los coeficientes de conversión de fluencia a dosis de 15 cantidades dosimétricas (Tabla 3.1) y calcular los valores de las 15 cantidades dosimétricas

(tabla 3.1 **Error! No se encuentra el origen de la referencia.**), utilizando la siguiente ecuación:

$$\zeta \times \int_{E_{\min}}^{E_{\max}} u_{\theta}(E) \theta_E(E) dE \quad (19)$$

Tabla 3.1. Coeficientes de conversión de fluencia a dosis (pSv-cm²)

Energía (eV)	E-AP	E-PA	E-RLAT	E-ROT	E-ISO
1.00E-03	5.24E+00	3.57E+00	1.38E+00	3.03E+00	2.43E+00
2.15E-03	5.63E+00	3.76E+00	1.45E+00	3.19E+00	2.53E+00
4.64E-03	6.11E+00	4.12E+00	1.59E+00	3.49E+00	2.74E+00
1.00E-02	6.55E+00	4.70E+00	1.82E+00	3.99E+00	3.06E+00
2.15E-02	7.60E+00	5.28E+00	2.03E+00	4.52E+00	3.35E+00
4.64E-02	8.87E+00	6.41E+00	2.45E+00	5.47E+00	3.95E+00
1.00E-01	9.95E+00	7.31E+00	2.79E+00	6.19E+00	4.41E+00
2.15E-01	1.13E+01	7.72E+00	2.98E+00	6.43E+00	4.66E+00
4.64E-01	1.29E+01	8.91E+00	3.40E+00	7.35E+00	5.28E+00
1.00E+00	1.39E+01	9.72E+00	3.74E+00	7.95E+00	5.72E+00
2.15E+00	1.42E+01	1.01E+01	3.80E+00	8.27E+00	5.89E+00
4.64E+00	1.47E+01	1.05E+01	4.04E+00	8.63E+00	6.24E+00
1.00E+01	1.49E+01	1.10E+01	4.13E+00	8.82E+00	6.41E+00
2.15E+01	1.49E+01	1.08E+01	4.14E+00	8.69E+00	6.39E+00
4.64E+01	1.45E+01	1.10E+01	4.14E+00	8.72E+00	6.44E+00
1.00E+02	1.45E+01	1.08E+01	4.11E+00	8.60E+00	6.37E+00
2.15E+02	1.43E+01	1.08E+01	4.07E+00	8.52E+00	6.18E+00
4.64E+02	1.42E+01	1.06E+01	4.02E+00	8.39E+00	6.11E+00
1.00E+03	1.43E+01	1.08E+01	4.01E+00	8.38E+00	6.05E+00
2.15E+03	1.48E+01	1.10E+01	4.07E+00	8.62E+00	6.26E+00
4.64E+03	1.67E+01	1.22E+01	4.57E+00	9.66E+00	6.97E+00
1.00E+04	1.89E+01	1.40E+01	5.22E+00	1.10E+01	8.02E+00
1.25E+04	2.05E+01	1.50E+01	5.62E+00	1.19E+01	8.71E+00
1.58E+04	2.25E+01	1.64E+01	6.15E+00	1.30E+01	9.63E+00
1.99E+04	2.50E+01	1.82E+01	6.83E+00	1.45E+01	1.08E+01
2.51E+04	2.80E+01	2.03E+01	7.67E+00	1.63E+01	1.22E+01
3.16E+04	3.17E+01	2.29E+01	8.70E+00	1.85E+01	1.40E+01
3.98E+04	3.60E+01	2.59E+01	9.90E+00	2.12E+01	1.61E+01
5.01E+04	4.12E+01	2.94E+01	1.14E+01	2.43E+01	1.86E+01
6.30E+04	4.75E+01	3.37E+01	1.34E+01	2.79E+01	2.16E+01
7.94E+04	5.52E+01	3.86E+01	1.54E+01	3.23E+01	2.52E+01
1.00E+05	6.48E+01	4.41E+01	1.75E+01	3.74E+01	2.93E+01
1.25E+05	7.67E+01	5.04E+01	2.03E+01	4.36E+01	3.38E+01
1.58E+05	9.09E+01	5.75E+01	2.36E+01	5.07E+01	3.92E+01
1.99E+05	1.07E+02	6.55E+01	2.75E+01	5.90E+01	4.56E+01

2.51E+05	1.27E+02	7.44E+01	3.20E+01	6.86E+01	5.26E+01
3.16E+05	1.49E+02	8.45E+01	3.72E+01	7.98E+01	6.05E+01
3.98E+05	1.74E+02	9.66E+01	4.34E+01	9.25E+01	6.99E+01
5.01E+05	2.02E+02	1.09E+02	5.05E+01	1.07E+02	8.08E+01
6.30E+05	2.32E+02	1.24E+02	5.87E+01	1.23E+02	9.34E+01
7.94E+05	2.65E+02	1.43E+02	6.86E+01	1.43E+02	1.07E+02
1.00E+06	2.99E+02	1.66E+02	8.12E+01	1.65E+02	1.25E+02
1.25E+06	3.36E+02	1.97E+02	9.80E+01	1.91E+02	1.42E+02
1.58E+06	3.70E+02	2.31E+02	1.18E+02	2.19E+02	1.63E+02
1.99E+06	3.96E+02	2.64E+02	1.40E+02	2.48E+02	1.89E+02
2.51E+06	4.25E+02	2.99E+02	1.64E+02	2.75E+02	2.13E+02
3.16E+06	4.48E+02	3.30E+02	1.87E+02	3.02E+02	2.37E+02
3.98E+06	4.66E+02	3.56E+02	2.07E+02	3.25E+02	2.61E+02
5.01E+06	4.80E+02	3.75E+02	2.26E+02	3.43E+02	2.79E+02
6.30E+06	4.90E+02	3.91E+02	2.44E+02	3.58E+02	2.90E+02
7.94E+06	4.96E+02	4.05E+02	2.60E+02	3.72E+02	3.02E+02
1.00E+07	4.98E+02	4.24E+02	2.80E+02	3.86E+02	3.25E+02
1.58E+07	4.80E+02	4.35E+02	3.04E+02	3.94E+02	3.43E+02
2.51E+07	4.57E+02	4.38E+02	3.24E+02	3.93E+02	0.00E+00
3.98E+07	4.36E+02	4.44E+02	3.58E+02	4.04E+02	0.00E+00
6.30E+07	4.28E+02	4.62E+02	4.03E+02	4.25E+02	0.00E+00
1.00E+08	4.32E+02	4.95E+02	4.68E+02	4.65E+02	0.00E+00
1.58E+08	4.62E+02	5.58E+02	5.95E+02	5.50E+02	0.00E+00
2.51E+08	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
3.98E+08	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
6.30E+08					

Energía (eV)	H*(10)	H _P (10, 0)	H _P (10, 45)	H _P (10, 60)	H _P (10, 75)
1.00E-03	6.75E+00	8.30E+00	4.29E+00	2.65E+00	1.15E+00
2.15E-03	7.29E+00	8.69E+00	4.53E+00	2.82E+00	1.23E+00
4.64E-03	8.29E+00	9.43E+00	5.01E+00	3.13E+00	1.39E+00
1.00E-02	9.78E+00	1.06E+01	5.84E+00	3.64E+00	1.61E+00
2.15E-02	1.06E+01	1.15E+01	6.90E+00	4.14E+00	1.71E+00
4.64E-02	1.27E+01	1.29E+01	8.00E+00	4.79E+00	1.98E+00
1.00E-01	1.34E+01	1.31E+01	8.34E+00	4.98E+00	2.03E+00
2.15E-01	1.26E+01	1.39E+01	9.08E+00	5.45E+00	2.22E+00
4.64E-01	1.31E+01	1.39E+01	9.15E+00	5.55E+00	2.30E+00
1.00E+00	1.29E+01	1.41E+01	9.30E+00	5.72E+00	2.38E+00
2.15E+00	1.26E+01	1.38E+01	9.12E+00	5.64E+00	2.42E+00
4.64E+00	1.16E+01	1.34E+01	8.86E+00	5.56E+00	2.44E+00
1.00E+01	1.10E+01	1.28E+01	8.35E+00	5.27E+00	2.37E+00
2.15E+01	1.04E+01	1.18E+01	7.82E+00	4.91E+00	2.24E+00
4.64E+01	9.93E+00	1.09E+01	7.17E+00	4.40E+00	2.08E+00
1.00E+02	9.26E+00	1.01E+01	6.57E+00	3.98E+00	1.91E+00
2.15E+02	8.77E+00	1.03E+01	6.15E+00	4.23E+00	1.80E+00

4.64E+02	8.25E+00	9.30E+00	5.70E+00	3.50E+00	1.70E+00
1.00E+03	7.85E+00	8.57E+00	5.52E+00	3.54E+00	1.72E+00
2.15E+03	7.98E+00	9.47E+00	5.79E+00	3.64E+00	1.71E+00
4.64E+03	8.69E+00	1.00E+01	6.08E+00	3.77E+00	1.70E+00
1.00E+04	1.13E+01	1.17E+01	7.55E+00	4.56E+00	1.79E+00
1.25E+04	1.28E+01	1.33E+01	8.74E+00	5.15E+00	1.87E+00
1.58E+04	1.51E+01	1.55E+01	1.04E+01	6.03E+00	2.00E+00
1.99E+04	1.82E+01	1.88E+01	1.27E+01	7.34E+00	2.25E+00
2.51E+04	2.23E+01	2.34E+01	1.57E+01	9.20E+00	2.69E+00
3.16E+04	2.80E+01	2.93E+01	1.96E+01	1.17E+01	3.35E+00
3.98E+04	3.61E+01	3.50E+01	2.43E+01	1.46E+01	4.16E+00
5.01E+04	4.69E+01	4.41E+01	3.15E+01	1.94E+01	5.62E+00
6.30E+04	6.07E+01	5.98E+01	4.35E+01	2.77E+01	8.24E+00
7.94E+04	7.81E+01	7.96E+01	5.87E+01	3.85E+01	1.17E+01
1.00E+05	9.91E+01	1.03E+02	7.69E+01	5.18E+01	1.61E+01
1.25E+05	1.24E+02	1.31E+02	9.94E+01	6.83E+01	2.22E+01
1.58E+05	1.54E+02	1.62E+02	1.26E+02	8.85E+01	3.04E+01
1.99E+05	1.86E+02	1.97E+02	1.56E+02	1.12E+02	4.10E+01
2.51E+05	2.22E+02	2.35E+02	1.91E+02	1.40E+02	5.44E+01
3.16E+05	2.61E+02	2.74E+02	2.29E+02	1.73E+02	7.09E+01
3.98E+05	3.02E+02	3.15E+02	2.70E+02	2.08E+02	9.08E+01
5.01E+05	3.42E+02	3.54E+02	3.11E+02	2.44E+02	1.14E+02
6.30E+05	3.76E+02	3.87E+02	3.49E+02	2.80E+02	1.40E+02
7.94E+05	3.98E+02	4.13E+02	3.81E+02	3.15E+02	1.70E+02
1.00E+06	4.27E+02	4.29E+02	4.06E+02	3.47E+02	1.94E+02
1.25E+06	4.14E+02	4.39E+02	4.22E+02	3.71E+02	2.48E+02
1.58E+06	3.97E+02	4.41E+02	4.32E+02	3.90E+02	2.89E+02
1.99E+06	4.13E+02	4.38E+02	4.39E+02	4.06E+02	2.82E+02
2.51E+06	4.13E+02	4.33E+02	4.41E+02	4.12E+02	3.02E+02
3.16E+06	4.09E+02	4.25E+02	4.37E+02	4.10E+02	3.14E+02
3.98E+06	4.06E+02	4.20E+02	4.34E+02	4.08E+02	3.25E+02
5.01E+06	4.01E+02	4.21E+02	4.37E+02	4.11E+02	3.39E+02
6.30E+06	4.05E+02	4.32E+02	4.48E+02	4.26E+02	3.62E+02
7.94E+06	4.18E+02	4.59E+02	4.74E+02	4.56E+02	3.97E+02
1.00E+07	4.91E+02	5.27E+02	5.38E+02	5.35E+02	4.76E+02
1.58E+07	5.96E+02	6.00E+02	6.15E+02	6.19E+02	5.70E+02
2.51E+07	4.00E+02	0.00E+00	0.00E+00	0.00E+00	0.00E+00
3.98E+07	3.99E+02	0.00E+00	0.00E+00	0.00E+00	0.00E+00
6.30E+07	3.20E+02	0.00E+00	0.00E+00	0.00E+00	0.00E+00
1.00E+08	2.59E+02	0.00E+00	0.00E+00	0.00E+00	0.00E+00
1.58E+08	2.59E+02	0.00E+00	0.00E+00	0.00E+00	0.00E+00
2.51E+08	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
3.98E+08	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
6.30E+08					

Energía (eV)	He-AP	He-PA	He-ROT	He-LAT	MADE
1.00E-03	2.46E+00	2.21E+00	2.03E+00	1.06E+00	7.49E+00
2.15E-03	2.89E+00	2.31E+00	2.09E+00	1.12E+00	8.45E+00
4.64E-03	3.34E+00	2.45E+00	2.17E+00	1.18E+00	9.38E+00
1.00E-02	3.75E+00	2.55E+00	2.24E+00	1.25E+00	1.02E+01
2.15E-02	4.08E+00	2.62E+00	2.31E+00	1.31E+00	1.08E+01
4.64E-02	4.31E+00	2.67E+00	2.37E+00	1.37E+00	1.13E+01
1.00E-01	4.50E+00	2.72E+00	2.44E+00	1.41E+00	1.18E+01
2.15E-01	4.67E+00	2.76E+00	2.52E+00	1.43E+00	1.22E+01
4.64E-01	4.79E+00	2.79E+00	2.60E+00	1.43E+00	1.25E+01
1.00E+00	4.79E+00	2.81E+00	2.62E+00	1.41E+00	1.26E+01
2.15E+00	4.68E+00	2.81E+00	2.57E+00	1.38E+00	1.24E+01
4.64E+00	4.53E+00	2.79E+00	2.51E+00	1.34E+00	1.22E+01
1.00E+01	4.40E+00	2.76E+00	2.45E+00	1.31E+00	1.20E+01
2.15E+01	4.29E+00	2.71E+00	2.40E+00	1.29E+00	1.18E+01
4.64E+01	4.19E+00	2.65E+00	2.35E+00	1.28E+00	1.16E+01
1.00E+02	4.06E+00	2.60E+00	2.29E+00	1.25E+00	1.14E+01
2.15E+02	3.92E+00	2.54E+00	2.23E+00	1.22E+00	1.11E+01
4.64E+02	3.84E+00	2.50E+00	2.18E+00	1.19E+00	1.06E+01
1.00E+03	3.76E+00	2.46E+00	2.14E+00	1.17E+00	9.77E+00
2.15E+03	3.77E+00	2.45E+00	2.13E+00	1.16E+00	9.12E+00
4.64E+03	4.13E+00	2.51E+00	2.26E+00	1.21E+00	9.16E+00
1.00E+04	4.68E+00	2.60E+00	2.46E+00	1.29E+00	1.06E+01
1.25E+04	5.05E+00	2.65E+00	2.59E+00	1.34E+00	1.24E+01
1.58E+04	5.55E+00	2.73E+00	2.77E+00	1.41E+00	1.48E+01
1.99E+04	6.24E+00	2.84E+00	3.02E+00	1.50E+00	1.77E+01
2.51E+04	7.18E+00	2.98E+00	3.35E+00	1.63E+00	2.11E+01
3.16E+04	8.39E+00	3.18E+00	3.79E+00	1.79E+00	2.51E+01
3.98E+04	9.97E+00	3.46E+00	4.36E+00	2.00E+00	2.99E+01
5.01E+04	1.19E+01	3.89E+00	5.11E+00	2.30E+00	3.60E+01
6.30E+04	1.45E+01	4.51E+00	6.10E+00	2.70E+00	4.35E+01
7.94E+04	1.78E+01	5.26E+00	7.38E+00	3.24E+00	5.26E+01
1.00E+05	2.20E+01	6.03E+00	9.00E+00	3.95E+00	6.34E+01
1.25E+05	2.75E+01	6.82E+00	1.10E+01	4.89E+00	7.61E+01
1.58E+05	3.44E+01	7.88E+00	1.36E+01	6.15E+00	9.10E+01
1.99E+05	4.29E+01	9.90E+00	1.71E+01	7.85E+00	1.08E+02
2.51E+05	5.31E+01	1.36E+01	2.18E+01	1.01E+01	1.28E+02
3.16E+05	6.51E+01	1.90E+01	2.77E+01	1.30E+01	1.51E+02
3.98E+05	7.93E+01	2.64E+01	3.48E+01	1.66E+01	1.80E+02
5.01E+05	9.53E+01	3.38E+01	4.24E+01	2.05E+01	2.19E+02
6.30E+05	1.13E+02	4.02E+01	5.04E+01	2.46E+01	2.63E+02
7.94E+05	1.32E+02	4.83E+01	6.00E+01	2.99E+01	3.07E+02
1.00E+06	1.53E+02	6.08E+01	7.25E+01	3.76E+01	3.43E+02
1.25E+06	1.76E+02	7.98E+01	8.88E+01	4.86E+01	3.70E+02
1.58E+06	2.01E+02	1.05E+02	1.08E+02	6.31E+01	3.89E+02

1.99E+06	2.27E+02	1.34E+02	1.31E+02	8.04E+01	4.02E+02
2.51E+06	2.56E+02	1.65E+02	1.55E+02	9.95E+01	4.09E+02
3.16E+06	2.85E+02	1.98E+02	1.81E+02	1.20E+02	4.10E+02
3.98E+06	3.13E+02	2.29E+02	2.07E+02	1.40E+02	4.08E+02
5.01E+06	3.39E+02	2.57E+02	2.30E+02	1.61E+02	4.07E+02
6.30E+06	3.66E+02	2.84E+02	2.54E+02	1.82E+02	4.06E+02
7.94E+06	3.93E+02	3.06E+02	2.77E+02	2.04E+02	4.06E+02
1.00E+07	4.56E+02	3.81E+02	3.40E+02	2.59E+02	4.13E+02
1.58E+07	5.49E+02	4.79E+02	3.99E+02	3.00E+02	4.26E+02
2.51E+07	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
3.98E+07	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
6.30E+07	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
1.00E+08	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
1.58E+08	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
2.51E+08	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
3.98E+08	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00
6.30E+08	0.00E+00	0.00E+00	0.00E+00	0.00E+00	0.00E+00

3. Extraer la información de 3 matrices de respuesta de tres detectores de neutrones. A continuación, se describe cada una:

- a. Detector de ^3He del PTB. Este detector está compuesto por 15 esferas de polietileno como se detalla: 0", 2.5", 3", 3.5", 4", 4.5", 5", 6", 7", 8", 9.5", 10", 12", 15" y 18".

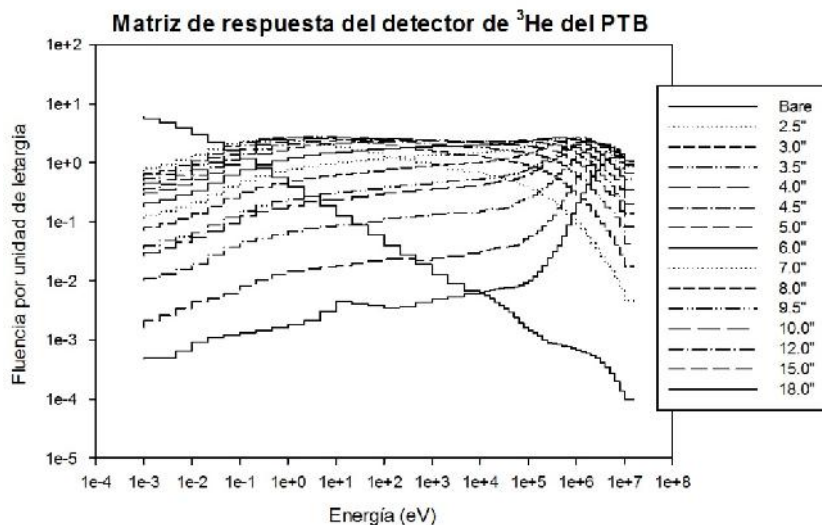


Figura 3.3. Matriz de respuesta del detector de ^3He del PTB

- b. Detector de ^3He del LALN. Este detector está compuesto por 11 esferas de polietileno como se detalla: 3", 4", 5", 6", 8", 9", 12", 18", 9"+Pb, 12"+Pb y 18"+Pb.




Figura 3.4. Matriz de respuesta del detector de ^3He del LALN

- c. Detector de $^6\text{LiI}(\text{Eu})$ del GSF. Este detector está compuesto por 10 esferas de polietileno como se detalla: 0", 2", 3", 5", 6", 8", 10", 12", 15" y 18".

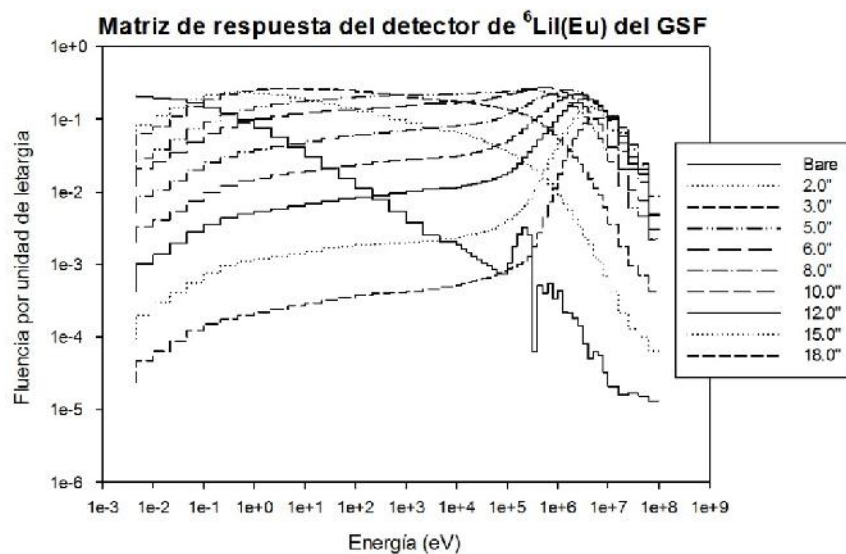


Figura 3.5. Matriz de respuesta del detector de $^6\text{LiI}(\text{Eu})$

- Convertir los espectros extraídos de unidades de letargia a unidades de energía utilizando la siguiente ecuación:

$$\Phi_E(E) = \Phi_E(u) * l \left(\frac{E_s}{E_{i_i}} \right) \quad (20)$$

Donde:

$\Phi_E(u)$ es el espectro de neutrones expresado en unidades de letargia

E_s es el intervalo de energía superior

E_{i_i} el intervalo de energía inferior

- Calcular las tasas de conteo. Esta información se calcula al multiplicar cada espectro de neutrones por la matriz de respuesta del SEEB para el cual se diseña la correspondiente RNA. Estos datos se utilizan como matriz de datos de entrada de la RNA.

3.2. Definición del valor crítico del *kernel de propagación constante* de RNARG

En las RNARG, un parámetro importante es la selección adecuada del “kernel de propagación constante”, la cual debe ser seleccionada antes de entrenar la RNA. Para realizar un ajuste muy cercano de los datos, se utiliza un valor de *spread* (propagación) más pequeño que la distancia típica entre los vectores de entrada. Para ajustar los datos de forma más suave, se utiliza un valor de *spread* mayor. Sin embargo, un valor de *spread* muy grande podría ocasionar un sobre ajuste, mientras que un valor muy pequeño podría ocasionar un sub ajuste. Por lo tanto, el valor de propagación constante puede ser considerado como un parámetro de regularización que tiene que ser seleccionado de manera óptima. [64], [64], [69]

Una vez que la RNA se entrena con los conjuntos de entrenamiento, los datos almacenados se aplican para validar el sistema. Entonces se calcula la suma del error medio cuadrático (MSE) entre cada espectro calculado por la red y el esperado. Tan pronto como se terminan de calcular todos los MSE, la media se selecciona como el valor correspondiente para este *kernel* de propagación constante específica.

Este procedimiento se repite a medida que se incrementa el valor de propagación constante, de tal forma que cada observación en la muestra se utiliza una vez como el dato de prueba. Entonces, en cada ocasión se aplica el 80% del conjunto de tasas de conteo que se utilizan como datos de entrada a la red y el 80% de los espectros de neutrones como salida. El restante 20% de ambos casos se utiliza en la etapa de prueba de la red con el propósito de probar el desempeño, siendo importante mencionar que estos datos no se utilizan en el proceso de entrenamiento. [30]

Cuando finaliza la rutina de programación creada para tal fin, se crea una gráfica como la mostrada en la Figura 3.6, en donde se muestra la curva de la suma de la media relativa del MSE de la predicción con el *kernel* de propagación continua seleccionada comparada con las demás.

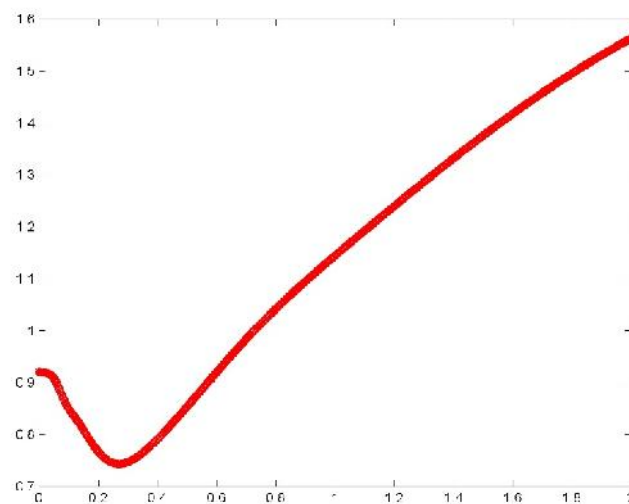


Figura 3.6. Valor óptimo del kernel de propagación constante

Como se muestra en la anterior, la metodología de entrenamiento de RNARG y el código de deconvolución de espectros de neutrones se automatizaron de forma simultánea en una única herramienta computacional empleando el lenguaje de programación de Matlab. Cabe resaltar que la metodología cae dentro de la categoría de técnicas avanzadas de minería de datos mediante la tecnología de RNA y que puede ser aplicada en la solución de diversos problemas de ciencia o ingeniería como por ejemplo en el área de la salud para el diagnóstico temprano de enfermedades humanas.

Como se aprecia en la Figura 3.7, la metodología de diseño de RNAG está compuesta de una serie de rutinas de programación que es transparente al usuario final. El código de deconvolución forma parte de la ventana principal de la herramienta de cómputo desarrollada. En esta ventana la única información de entrada es la correspondiente a las tasas de conteo medidas con un SEEB con un detector de neutrones a base de detectores de Helio (^3He) o de Litio ($^6\text{Li}(\text{Eu})$).

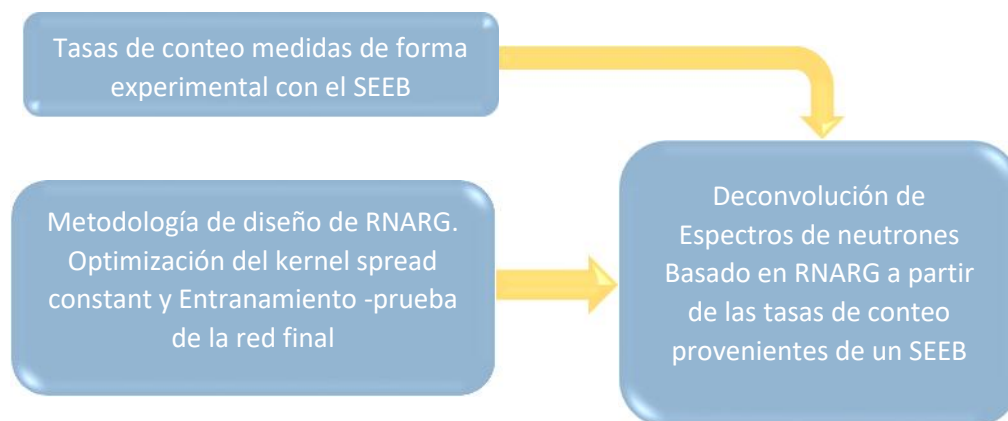


Figura 3.7. Código de deconvolución de espectrometría y dosimetría de neutrones Basado en RNARG

En virtud de que se trata de un proceso de entrenamiento en la que los datos se ingresan a la red una única ocasión, el tiempo de entrenamiento de este tipo de arquitectura de red está en el orden de las fracciones de segundo, con un valor

promedio de 0.058 segundos, lo que comparado con las RNAPAPI es significativamente inferior. [30]

Es importante destacar que al utilizar la herramienta de cómputo desarrollada en este trabajo de tesis, el tiempo promedio para calcular el valor óptimo del kernel de propagación constante es de 154 segundos, tiempo en el que se realiza el entrenamiento de 2000 RNARG.

Una vez calculado el valor de la mencionado, la siguiente etapa implica entrenar la RNARG.

3.3. Entrenamiento de la RNRG

El entrenamiento de las RNARG aplicadas en el ámbito de la espectrometría y dosimetría neutrónicas se realiza de la siguiente manera: La Figura 3.8 muestra la ventana principal del código NSDGRANN basado en la metodología de entrenamiento de RNARG. En ésta puede seleccionarse el directorio de trabajo a través de un botón de selección etiquetado como “Directorio de trabajo”. Al dar clic en este botón se abre una ventana como la mostrada en la Figura 3.9 que permite seleccionar una carpeta de trabajo o en su defecto crear una nueva. En la ruta seleccionada serán almacenados los datos generados en el proceso de entrenamiento.

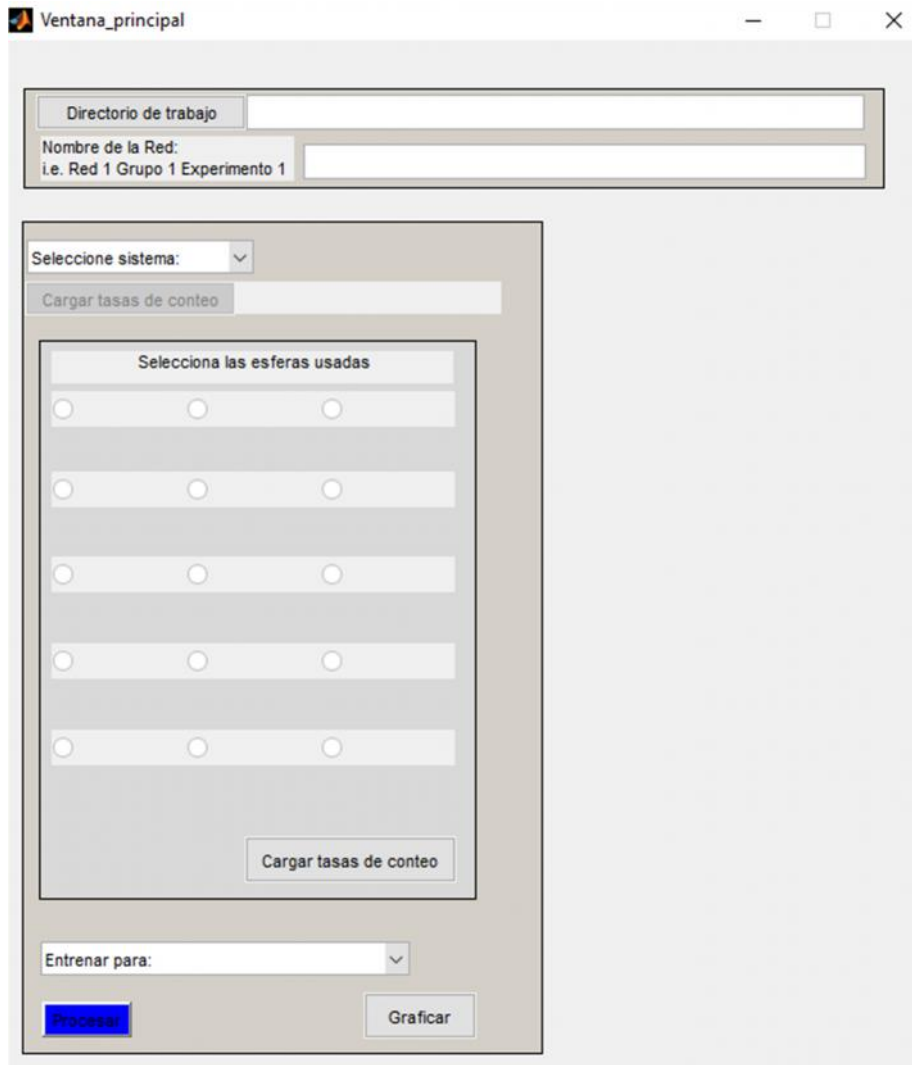


Figura 3.8. Ventana principal de la herramienta computacional diseñada en base a la tecnología de RNARG con aplicación en espectrometría y dosimetría neutrónica




Figura 3.9. Selección del directorio de trabajo

Como se observa en la Figura 3.8, la ventana principal de la herramienta desarrollada tiene una caja de texto etiquetada como “Nombre de Red” que permite asignar un identificador al entrenamiento que se esté realizando. Esta información será

almacenada para identificar los entrenamientos realizados y realizar un análisis posterior.

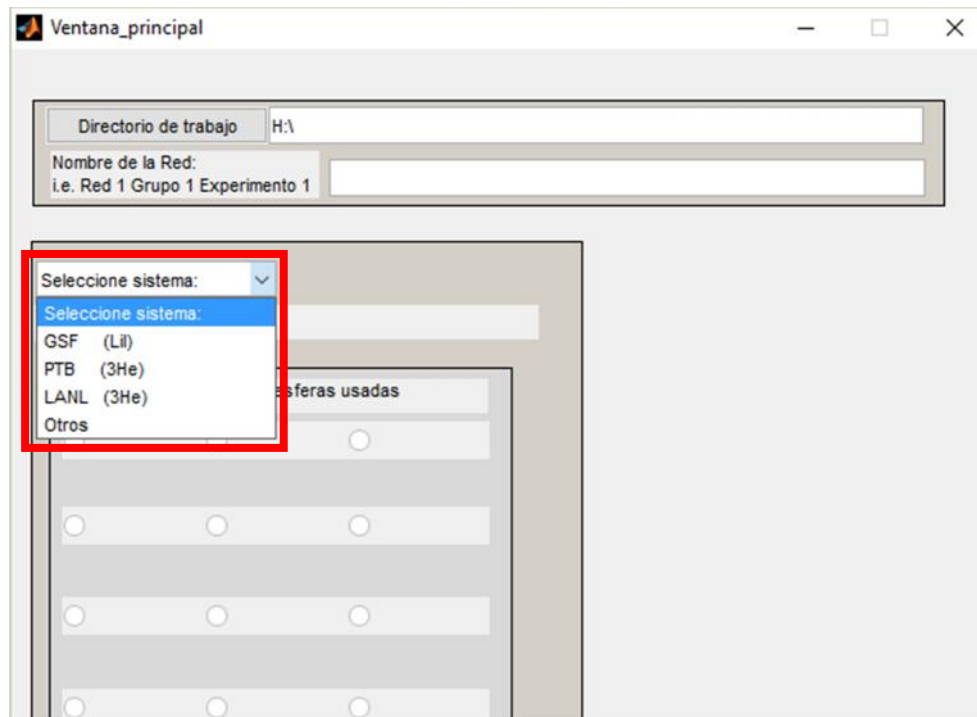


Figura 3.10. Selección de la matriz de respuesta con el que será entrenada la RNARG

De igual forma, la ventana principal de la herramienta computacional tiene un menú desplegable de selección etiquetado como “Seleccione sistema” en donde el usuario final puede elegir la matriz de respuesta con la que será entrenada la RNARG. Como se puede observar en la Figura 3.10, el código desarrollado incluye 3 matrices de respuesta, las cuales fueron extraídas del compendio de la IAEA [72]. Al dar clic en alguna de ellas, se abre una ventana como la mostrada en las figuras 3.11, 3.12 y 3.13, en las que se pueden apreciar las esferas Bonner que tiene el sistema.

The screenshot shows a software interface for selecting Bonner spheres. At the top, there is a dropdown menu set to "GSF (Li)". Below it is a button labeled "Cargar tasas de conteo". The main section is titled "Selecciona las esferas usadas" and contains a grid of radio buttons for sphere sizes: bare, 8", 2", 10", 3", 12", 5", 15", 6", and 18". At the bottom right of this section is another button labeled "Cargar tasas de conteo".

Figura 3.11. Selección de las esferas Bonner de una medición realizada con un detector de ^3He que utiliza la matriz de respuesta GSF del compendio de la IAEA

The screenshot shows a software interface for selecting Bonner spheres. At the top, there is a dropdown menu set to "PTB (3He)". Below it is a button labeled "Cargar tasas de conteo". The main section is titled "Selecciona las esferas usadas" and contains a grid of radio buttons for sphere sizes: bare, 4.5", 9.5", 2.5", 5", 10", 3", 6", 12", 3.5", 7", 15", 4", 8", and 18". At the bottom right of this section is another button labeled "Cargar tasas de conteo".

Figura 3.12. Selección de las esferas Bonner de una medición realizada con un detector de ^3He que utiliza la matriz de respuesta PTB del compendio de la IAEA

LANL (3He) v

Cargar tasas de conteo

Selecciona las esferas usadas

3" 9" 18+Pb

4" 12"

5" 18"

6" 9+Pb"

8" 12+Pb

Cargar tasas de conteo

Figura 3.13. Selección de las esferas Bonner de una medición realizada con un detector de 3He que utiliza la matriz de respuesta LANL del compendio de la IAEA

Una característica importante del sistema y que demuestra el poder de predicción y clasificación de esta herramienta tecnológica basada en RNARG, es el hecho de que el usuario final no tiene que utilizar todas las esferas Bonner mostradas en las ventanas de las figuras anteriores. El código tiene la flexibilidad de permitir elegir al usuario final las esferas Bonner con las que se desee realizar el entrenamiento de la RNA. Al hacer lo anterior se genera una caja de texto que permite escribir las lecturas tomadas de forma experimental con el SEEB correspondiente, como se muestra en la figura siguiente.

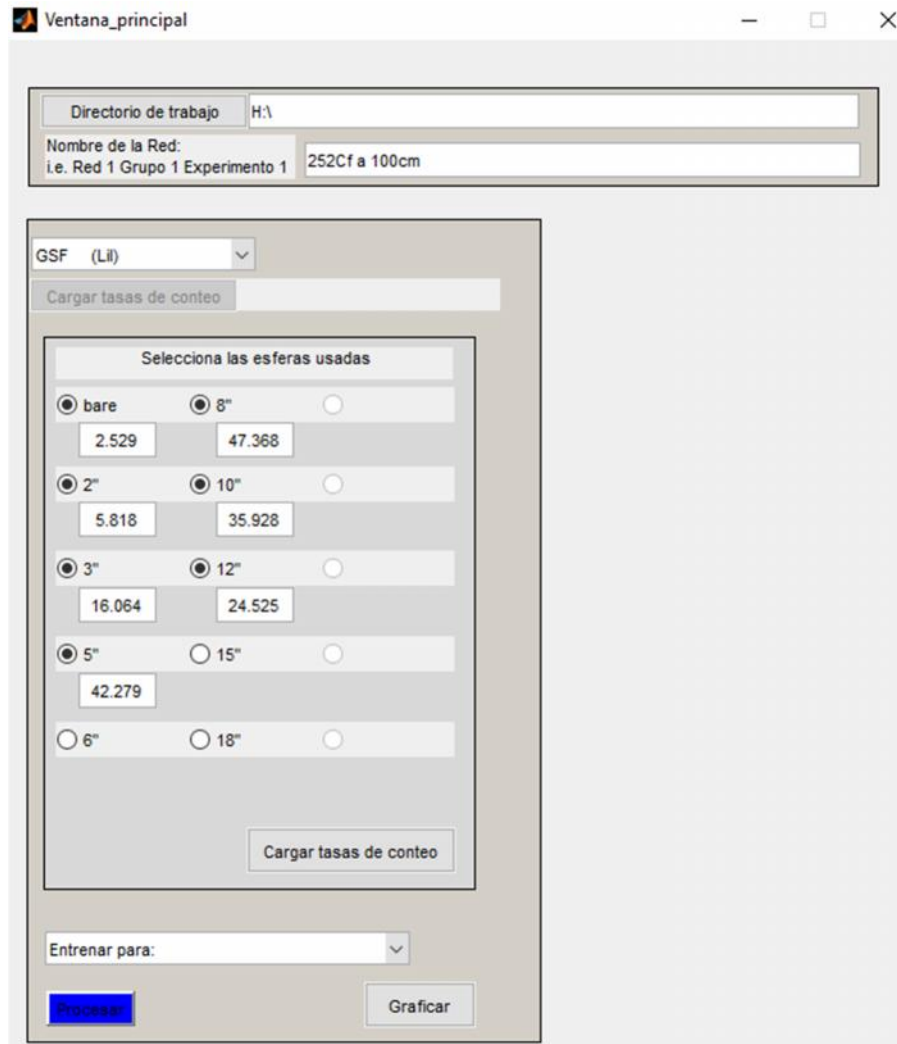


Figura 3.14. Selección de esferas y captura de datos experimentales para entrenamiento y reconstrucción del espectro, así como el cálculo simultáneo de 15 cantidades dosimétricas

A diferencia de las técnicas clásicas basadas en métodos numéricos tradicionales, en virtud de que las RNARG emplean métodos estadísticos para realizar la clasificación y predicción de los datos de salida utilizando la información contenida en los datos de entrada en una sola iteración, se ha observado que este tipo de tecnología tiene la capacidad de clasificar espectros y calcular dosis empleando menos información de entrada, esto es, menos esferas Bonner. Actualmente, se están realizando experimentos que demuestran que este tipo de tecnología es capaz de realizar la reconstrucción del espectro y el cálculo de las cantidades dosimétricas utilizando como datos de entrada dos esferas Bonner.

Posteriormente, como se muestra en la Figura 3.15, una vez seleccionada la matriz de respuesta con la que se realizará el entrenamiento, seleccionado el número de detectores adecuado e ingresados los valores experimentales medidos con el SEEB, en el menú desplegable etiquetado como “Entrenar para”, el usuario final tiene la posibilidad de elegir de entre las opciones que se aprecian en la figura.

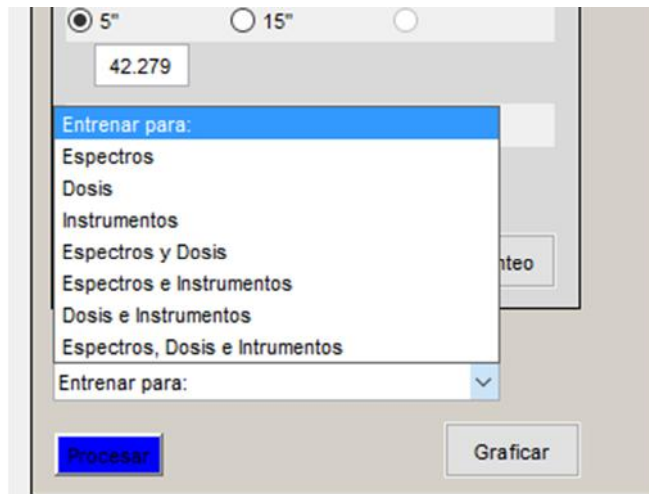


Figura 3.15. Selección de la tarea de entrenamiento deseada

Finalmente, la RNARG está lista para ser entrenada, para ello el usuario final da clic en el botón etiquetado como “Procesar”, en este momento se entrena la RNARG y se calculan los espectros, dosis o ambos, de acuerdo con la selección realizada en etapas anteriores.

Es importante mencionar que en la fase inicial de ejecución del código, se realiza de forma transparente la selección del valor óptimo del kernel de propagación constante en el que las rutinas de programación desarrolladas realizan el entrenamiento de 2000 RNARG en un tiempo promedio de 154 segundos con el objetivo de elegir el valor optimizado que será utilizado en la etapa de entrenamiento de la RNARG final. Al realizar la selección del valor óptimo de propagación constante se muestra una gráfica como la mostrada en la Figura 3.16.

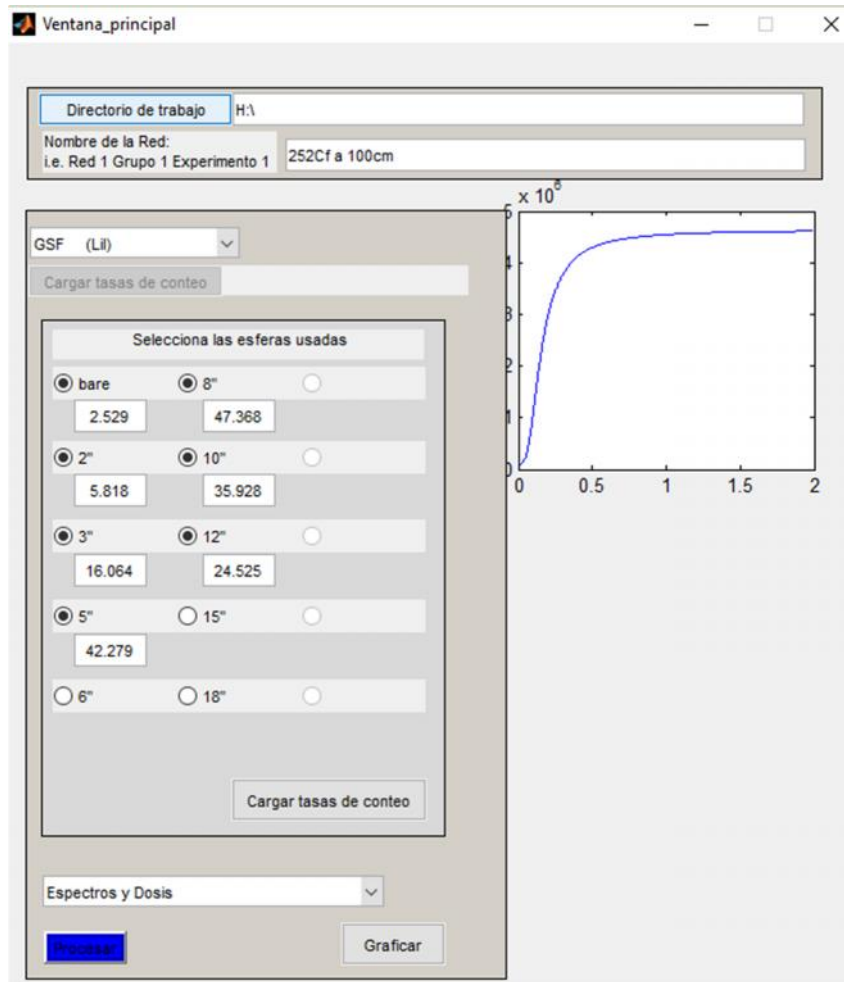


Figura 3.16. Gráfica que muestra el valor del kernel de propagación constante

3.3.1. Reconstrucción del espectro y cálculo de cantidades dosimétricas

Una de las características que hacen interesante al código NSDGRANN (Neutron Spectrometry and Dosimetry by means Generalized Regression Artificial Neural Networks), es el hecho de que la única información que el usuario debe proporcionar al programa son las tasas de conteo medidas de forma experimental con un SEEB, siendo posible reducir a dos el número de esferas Bonner. Empleando únicamente esta información, el código tiene la capacidad de reconstruir espectros de neutrones, calcular 15 cantidades dosimétricas. Lo anterior representa una diferencia significativa en comparación con los códigos de deconvolución tradicionales, en los que tan solo para la reconstrucción del espectro de neutrones, se requiere proporcionar un conjunto

de parámetros específicos que solo una persona especializada es capaz de conocer. [45], [46]

Sin embargo, la naturaleza intrínseca de las RNA requiere que los datos de entrada, en este caso las tasas de conteo medidas con el SEEB, se encuentren normalizados a uno para poder realizar la reconstrucción de los espectros. De igual forma, debido a esta naturaleza de las redes, la salida de los datos los entrega también normalizados a un valor de uno.

Lo anterior representa una situación difícil ya que en este formato, los espectros y dosis obtenidos con las RNA no tienen significado físico, por lo que no se pueden aplicar en situaciones experimentales reales debido a que no se pueden interpretar ni analizar los resultados.

Debido a que el código NSDGRANN es una herramienta basada en la tecnología de RNARG, al momento de crearla se presentó el problema expuesto en el párrafo anterior. La situación se resolvió al diseñar una rutina de programación para normalizar las tasas de conteo en la etapa inicial, y otra rutina que desnormaliza los espectros de neutrones y dosis calculados.

Esta medida hizo práctico el uso de esta herramienta en ambientes experimentales reales, aunado a su facilidad y rapidez de operación. Por esta razón, después de haber seleccionado la matriz de respuesta deseada y las esferas Bonner a ser utilizadas, deberán ser escritos sin normalizar, los valores numéricos de las tasas de conteo provenientes del SEEB.

Es importante mencionar que a diferencia de los códigos de deconvolución tradicionales, en el código NSDGRANN no se requiere proporcionar al programa información a "priori", como es el caso de un espectro inicial, para realizar la reconstrucción del espectro de neutrones o el cálculo de las cantidades dosimétricas

[24], [26], [29], [30], [92]. Por sus características de diseño, esta herramienta resulta práctica en ambientes experimentales reales.

3.3.2. Aplicación de la herramienta diseñada en experimentos reales

En ambientes experimentales reales en los que se emplea el SEEB, se miden las tasas de conteo que los neutrones producen en múltiples configuraciones de combinación detector-moderador. La técnica de las esferas Bonner, involucra recolectar pulsos electrónicos a través de la electrónica asociada como la ilustrada en las figuras 3.14 y 3.15, que surgen de las interacciones entre los neutrones y los átomos de ${}^6\text{Li}$ en un detector de Ioduro de Litio dopado con Europio por ejemplo (${}^6\text{LiI}(\text{Eu})$), con el detector en diferentes configuraciones de conteo en el campo de irradiación de neutrones.

El SEEB basado en un detector de neutrones térmicos compuesto de ${}^6\text{LiI}(\text{Eu})$, como se ilustra en la Figura 3.17, está integrado por el detector desnudo y 6 esferas de polietileno cuyas dimensiones son 0, 2, 3, 5, 8, 10 y 12 pulgadas respectivamente.





Figura 3.17. SEEB con detector ${}^6\text{LiI}(\text{Eu})$

El SEEB basado en un detector de neutrones térmicos compuesto de ^3He , como se observa en la Figura 3.18, está integrado por 12 esferas de polietileno cuyas dimensiones son 3, 3.5, 4, 4.5, 5, 6, 7, 8, 9, 9.5, 10 y 12 pulgadas respectivamente.



(a) Detector ^3He



(b) Esferas Bonner para el detector de ^3He

Figura 3.18. SEEB con detector ^3He

Para obtener las tasas de conteo mediante el SEEB, se realiza una serie de medidas a cierta distancia respecto de la fuente de neutrones, colocando el detector de neutrones en el centro de cada esfera de polietileno. Es importante mencionar que entre menor sea el tamaño de la esfera utilizada, es mayor el tiempo de medición requerido, debido a la baja interacción que los neutrones tienen con la materia.

La combinación detector-moderador tendrá una respuesta diferente a los neutrones en función de la energía. Los neutrones rápidos se frenan dentro del moderador y llegan al detector en estado térmico, mientras que los neutrones inicialmente termalizados son parcialmente capturados dentro del moderador y no alcanzan el detector. Aumentando el diámetro de la esfera moderadora, se desplaza el pico de sensibilidad del sistema hacia las energías altas y de esta manera es posible efectuar una espectrometría de neutrones. [20], [105]–[107]

Tanto para la espectrometría como para la dosimetría de neutrones, se utilizan estas interacciones, ya que al producir partículas cargadas, éstas inducen en la instrumentación por medio de la ionización señales eléctricas a partir de las cuales y mediante procedimientos adecuados, se remonta a la energía del neutrón detectado.

A partir de las tasas de conteo tomadas con las esferas, es posible reconstruir el espectro de neutrones, el cual proporciona información acerca de la distribución de energía de los neutrones incidentes. Sin embargo, el simple hecho de medir las tasas de conteo con el SEEB, no permite realizar la reconstrucción del espectro.

Para ello es necesario hacer uso de diversos códigos de deconvolución que resuelvan la ecuación integral diferencial de Fredholm de primer tipo, que como se ha comentado en secciones anteriores, es un sistema de ecuaciones mal condicionado, con un número infinito de soluciones. El seleccionar aquella solución que tenga significado para el tipo de problema, es parte del proceso de reconstrucción, por lo que se debe aplicar algún procedimiento para la deconvolución del espectro. [24], [29], [35], [100], [102], [103], [108]

Al utilizar las cuentas integrales leídas a partir del SEEB es posible reconstruir el espectro de neutrones empleando varios métodos, entre los que se pueden mencionar: los métodos Monte Carlo, de la máxima entropía, de parametrización, iterativos y en este trabajo, empleando la tecnología de RNARG. [27], [34], [109], [110]

Es importante mencionar que los resultados obtenidos en distintas etapas del desarrollo de este proyecto de tesis doctoral han sido publicados como artículos en revistas con índices de impacto y como artículos en congresos internacionales.

Para evaluar el desempeño del código NSDGRANN se utilizaron tasas de conteo medidas en situaciones experimentales reales con dos SEEB que tienen como base detectores de ${}^6\text{LiI}(\text{Eu})$ y ${}^3\text{He}$. En el procedimiento de medición experimental participan las siguientes instituciones:

1. La Unidad Académica de Estudios Nucleares (UAEN), perteneciente a la Universidad Autónoma de Zacatecas (UAZ), México.
2. El Centro Estatal de Cancerología del Estado de Nayarit, México.

3. El Instituto Nacional de Investigaciones Nucleares en México.
4. El Departamento de Ingeniería Nuclear (DIN), de la Universidad Politécnica de Madrid (UPM) en España.
5. El Laboratorio de Patrones Neutrónicos (LPN), perteneciente al Laboratorio de Metrología de Radiaciones Ionizantes (LMRI) del Centro de Investigaciones Energéticas Medio Ambientales y Tecnológicas (CIEMAT), con sede en Madrid, España.

Cabe mencionar que las instituciones 1 a 4 utilizan un SEEB con detector de ${}^6\text{Li}(\text{Eu})$. La institución 5 emplea un SEEB con detector de ${}^3\text{He}$.

Como se ha mencionado, el código NSDGRANN fue diseñado para ser utilizado en situaciones experimentales reales. A través de la co-asesoría de una tesis de maestría se aplicó la metodología desarrollada en base al entrenamiento de RNARG, con el objetivo de observar el desempeño y capacidad de generalización de las redes entrenadas. De los experimentos realizados, se pudo observar que este tipo de redes son capaces de realizar las tareas de clasificación y predicción de la información empleando menos información de entrada en contraste con las técnicas clásicas que emplean métodos tradicionales basados en métodos numéricos clásicos.

3.4. Comparando resultados obtenidos frente a métodos clásicos

Con el objetivo de comparar los resultados obtenidos con las RNARG implementadas en el código NSDGRANN frente a las obtenidas con herramientas clásicas, se co-asesoraron 3 tesis de licenciatura cuyo objetivo fue realizar el diseño y optimización de arquitecturas de RNAPAPI optimizadas por medio de la Metodología de Diseño Robusto de Redes Neuronales Artificiales (MDRRNA). Los resultados obtenidos con las RNAPAPI se compararon frente a los obtenidos con las RNARG en donde se pudo observar que los espectros y dosis calculados con ambas técnicas presentan desempeños y capacidad de generalización similares. Sin embargo, con el uso de

RNARG se simplifica de forma significativa el procedimiento en el proceso de reconstrucción ya que para el caso de las RNARG solo se requiere la optimización de un parámetro, proceso que se encuentra automatizado en la herramienta tecnológica diseñada.

De igual forma, en un capítulo de libro se presentan los resultados obtenidos al comparar las metodologías basadas en RNAPAPI optimizadas por medio de la MDRRNA frente a los obtenidos con RNARG mediante el código NSDGRANN. De los resultados obtenidos se pudo apreciar que ambas técnicas se basan en principios distintos, aunque persiguen un objetivo común: optimizar los parámetros de arquitectura y de aprendizaje de RNA. Sin embargo, debido a lo novedoso de estas metodologías, también se pudo observar que se carece de herramientas para realizar el procesamiento, análisis y presentación de la información calculada por las redes en ambientes experimentales reales.

Una vez realizadas las mediciones explicadas en el párrafo anterior, a la fecha se está realizando una etapa de comparación de los resultados obtenidos con las herramientas tecnológicas diseñadas, frente a los resultados obtenidos utilizando las metodologías clásicas empleadas en la actualidad en los distintos laboratorios, tales como códigos NSDUAZ y NSDANN en el caso de las instituciones de México y la UPM de España y el código UMG en el caso de CIEMAT de España.

Capítulo 4

Resultados y discusión

Como se ilustra en la Figura 4.1, en la realización de esta tesis doctoral se estudió, analizó, diseñó e implementó una metodología de entrenamiento de RNA basada en la tecnología de RNARG. De igual forma, se diseñó un código de deconvolución de espectros de neutrones basado en la misma tecnología, el cual es flexible y versátil ya que permite entrenar RNA en el ámbito de la espectrometría y dosimetría neutrónica empleando los dos SEEB más utilizados, uno basado en un detector de neutrones de ${}^6\text{LiI}(\text{Eu})$ y el otro en un detector de ${}^3\text{He}$ a través de las matrices de respuesta tomadas del compendio de espectros de neutrones compilado por la IAEA.

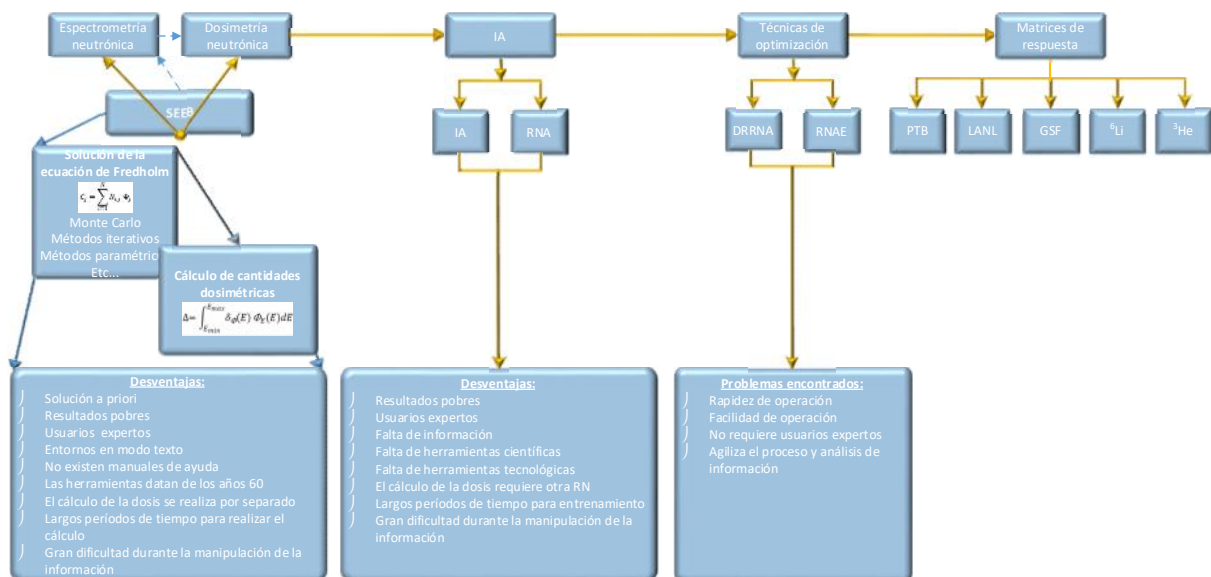


Figura 4.1. Desarrollo de Herramientas de cómputo en base a MDRRNA y RNAE

El código de deconvolución en cuestión permite seleccionar tres matrices de respuesta y dentro de ésta el número de esferas Bonner con los que se realiza el entrenamiento de las RNA. El código tiene la capacidad de reconstruir espectros de neutrones y/o calcular 15 cantidades dosimétricas de forma.

Resultados parciales de las técnicas, herramientas y desarrollos tecnológicos realizadas en el presente proyecto de investigación, fueron presentados en múltiples congresos internacionales. Los resultados más relevantes se publicaron en revistas con índices de impacto, proceedings de congresos internacionales y en un capítulo de libro. De igual forma, se participó en la formación de capital humanos altamente calificados a través de la co-asesoría de 3 tesis de licenciatura y 1 tesis de maestría. Finalmente, se realizó la protección de derechos de autor de los desarrollos de innovación tecnológica realizados. Los productos derivados se enlistan y se muestran a continuación.

4.1. Capítulos de libro

1. Martínez-Blanco, MR; Castañeda-Miranda, VH; Ornelas-Vargas, G; Guerrero-Osuna, HA; Solís-Sánchez, LO; Castañeda-Miranda, R; Celaya Padilla JM; Vega-Carrillo, HR; Martínez Fierro M; Garza Veloz I, Ortiz-Rodríguez, JM. **Generalized Regression Neural Networks with Application in Neutron Spectrometry**. Book: Artificial Neural Networks - Models and Applications", ISBN 978-953-51-4713-8. 2016.

En este capítulo de libro se realiza una comparación del desempeño de RNAPAPI frente al desempeño obtenido con RNARG aplicados en el ámbito de la espectrometría de neutrones. Se describen ambas arquitecturas de red poniendo mayor énfasis en las redes neuronales estadísticas, describiendo los aspectos fundamentales de las mismas resaltando las características de las RNARG. Se comparan los resultados obtenidos al entrenar los dos tipos de arquitectura de red empleando los mismos datos

con el objetivo de comparar los resultados en el dominio de la espectrometría de neutrones. Se pudo observar que el desempeño obtenido con ambas redes es muy parecido, sin embargo, también se observó que trabajar con RNARG es mucho más simple y rápido, por lo que se propone a este tipo de arquitectura de red como una alternativa prometedora en la solución del problema de reconstruir el espectro de neutrones empleando como datos de entrada las tasas de conteo provenientes de un SEBB.

4.2. Artículos con índices de impacto

1. Martínez-Blanco, M. del R., Ornelas-Vargas, G., Solís-Sánchez, L. O., Castañeda-Miranada, R., Vega-Carrillo, H. R., Celaya-Padilla, J. M., Garza-Veloz, I, Martínez-Fierro, I. and Ortiz-Rodríguez, J. M. (2016). **A comparison of back propagation and Generalized Regression Neural Networks performance in neutron spectrometry**. Applied Radiation and Isotopes, 117, 20–26. <https://doi.org/10.1016/j.apradiso.2016.04.011>

El objetivo central de este artículo es realizar una comparación del desempeño obtenido con RNAPAPI frente al obtenido con RNARG en la solución de la reconstrucción del espectro de neutrones utilizando como información de entrada las tasas de conteo obtenidas con un sistema espectrométrico de esferas Bonner. Los resultados obtenidos muestran que para determinar la topología óptima de una RNAPAPI se requirieron 36 entrenamientos de distintas arquitecturas de red con diferentes parámetros cada una entrenada en un promedio de 8 minutos. En el caso de la RNARG solo se requirió calcular un valor de dispersión asociado con la función de base radial, para ello, se entrenaron 2000 mil redes neuronales en un promedio de 154 segundos. Los resultados obtenidos muestran que ambas arquitecturas muestran resultados muy parecidos, la diferencia radica en la simplicidad de uso y rapidez de las RNRG, por lo que se proponen como una técnica alternativa con posibilidades de sustituir a la tecnología basada en RNAPAPI.

2. Martínez-Blanco, M. del R., Ornelas-Vargas, G., Castañeda-Miranda, C. L., Solís-Sánchez, L. O., Castañeda-Miranada, R., Vega-Carrillo, H. R., Garza-Veloz, I., Martínez-Fierro, M. and Ortiz-Rodríguez, J. M. (2016). **A neutron spectrum unfolding code based on generalized regression artificial neural networks.** Applied Radiation and Isotopes, 117, 8-14. <https://doi.org/10.1016/j.apradiso.2016.04.029>

En este artículo se muestran avances en el desarrollo de un código de deconvolución basado en la tecnología de RNARG con utilidad potencial en ambientes experimentales, de investigación y de laboratorio reales.

3. JM Ortiz-Rodriguez, MR Martinez-Blanco, G. Ornelas Vargas, HA Guerrero Osuna, JH Mendoza Hasso and R Castañeda Miranda (2016). **A Study Using the Robust Design of Artificial Neural Networks Methodology in Neutron Spectrometry.** 2016 IEEE International Conference on Industrial Technology (ICIT), 1600-1606, DOI: 10.1109/ICIT.2016.7475000.

En este artículo se describen los principios de operación de la Metodología de Diseño Robusto de Redes Neuronales Artificiales (MDRRNA) que en base a técnicas estadísticas, permite determinar la topología cercana a lo óptimo de RNAPAPI. En este trabajo la metodología se aplica en el ámbito de la espectrometría neutrónica, entrenando más de 1000 diferentes arquitecturas de red neuronal bajo diferentes criterios de estudio. Los resultados obtenidos demuestran que esta metodología es una técnica poderosa en la determinación de los parámetros de la arquitectura de red de RNAPAPI ya que reduce considerablemente el tiempo de entrenamiento y el esfuerzo requerido en esta actividad al utilizar una técnica metodológica y sistemática.

4.3. Participación en congresos

4.3.1. Año 2015

1. Ortiz-Rodríguez, JM; Martínez-Blanco, MR; Castañeda-Miranda, R; Solís-Sánchez, LO; Vega-Carrillo, HR. (2015). **A comparison of back propagation and generalized regression neural networks performance in neutron spectrometry.** XV International Symposium on Solid State Dosimetry (ISSSD 2015) Proceedings. León, Gto. México. Pp. 898-907.

En este trabajo se describe una comparación de resultados obtenidos en la reconstrucción de espectros de neutrones y cálculo de 15 cantidades dosimétricas mediante la tecnología de redes neuronales artificiales de propagación inversa frente a las redes neuronales artificiales de regresión generalizada.

2. Ortiz-Rodríguez, JM; Martínez-Blanco, MR; Castañeda-Miranda, R; Solís-Sánchez, LO; Vega-Carrillo, HR. (2015). **A neutron spectrum unfolding code based on generalized regression artificial neural networks.** XV International Symposium on Solid State Dosimetry (ISSSD 2015) Proceedings. León, Gto. México. Pp. 869-897.

En este trabajo se describe el proceso de reconstrucción de espectros de neutrones mediante la tecnología de redes neuronales artificiales de regresión generalizada, señalando las ventajas de implementar esta tecnología.

4.3.2. Año 2016

3. Ortiz-Rodriguez J.M., Martinez-Blanco M.R., Ornelas-Vargas G., Guerrero-Ozuna H.A., Mendoza-Hasso J.H., Solis-Sanchez L.O., and Castañeda-Miranda R. **A Study Using the Robust Design of Artificial Neural Networks Methodology in Neutron Spectrometry.** 2016 IEEE International Conference

on Industrial Technology (ICIT2016), March 14-17, 2016 in Taipei, Taiwan. 978-1-4673-8074-4/16/\$31.00 ©2016 IEEE

En este trabajo se describe un proceso sistemático y metodológico de optimización de redes neuronales artificiales basado en la metodología Taguchi y diseño de experimentos para el diseño, entrenamiento y prueba de redes neuronales artificiales aplicadas al área de espectrometría de neutrones.

4. Martínez-Blanco, M.R.; Castañeda-Miranda, V.H.; Solis-Sánchez, L.O.; Castañeda-Miranda, R.; Ornelas-Vargas, G.; Guerrero-Osuna, H.A.; Vega-Carrillo, H.R.; Ortiz-Rodríguez, J.M. (2016). **Automatización del proceso de entrenamiento de redes neuronales de regresión generalizada aplicadas a la espectrometría de neutrones.** Book of Abstracts of the XVI International Symposium on Solid State Dosimetry (ISSSD 2016). Tuxtla Gutiérrez, Chis., Mexico. Pág. 4.

En este trabajo se describen avances en el desarrollo de un proceso de automatización de una metodología para el entrenamiento de RNARG con orientación a resolver problemas asociados con espectrometría y dosimetría neutrónica.

5. Castañeda-Miranda, V.H.; Martínez-Blanco, M.R.; Solis-Sánchez, L.O.; Castañeda-Miranda, R.; Vega-Carrillo, H.R.; Ortiz-Rodríguez, J.M. (2016). **Herramienta en software para resolución de problemas inversos mediante técnicas de Inteligencia Artificial: Una aplicación en espectrometría neutrónica.** XVI International Symposium on Solid State Dosimetry (ISSSD 2016) Proceedings, Volume 1. Tuxtla Gutiérrez, Chis., Mexico. Pp. 193-205.

Trabajo de colaboración con otro alumno de doctorado que busca automatizar en una herramienta de cómputo la metodología de diseño robusto de redes neuronales artificiales. En base a la experiencia que se tiene en este dominio de conocimiento, en este proyecto se ha colaborado con ideas y sugerencias en la implementación de dicha

herramienta tecnológica, que ha derivado en los avances presentados en este documento.

6. Jorge Armando Ortiz Murillo, José María Celaya Padilla, Ma. del Rosario Martínez Blanco, Luis Octavio Solís Sánchez, Rodrigo Castañeda Miranda, Idalia Garza Veloz, Margarita Martínez Fierro, Yamilé López Hernández & José Manuel Ortiz-Rodríguez. **Detección de cáncer de mama usando técnicas avanzadas de minería de datos con redes neuronales.** XVI International Symposium on Solid State Dosimetry (ISSSD 2016) Proceedings, Volume 2. Tuxtla Gutiérrez, Chis., Mexico. Pp. 153-170.

Como parte de los desarrollos que se realizan al interior del LIDTIA, en este trabajo que corresponde a un estudiante de maestría, se exploran arquitecturas de redes neuronales artificiales aplicadas en el diagnóstico temprano de cáncer de mama en base a información extraída de tomografías computarizadas tomadas con mastógrafos en hospitales. En base a la experiencia adquirida, se colabora en la asesoría de dicho estudiante en lo que se refiere a las distintas arquitecturas de red neuronal a ser exploradas: RNAPAPI y/o RNARG.

7. Jose Maria Celaya Padilla, Jorge Armando Ortiz Murillo, Maria del Rosario Martínez Blanco, Luis Octavio Solís Sánchez, Rodrigo Castañeda Miranda, Idalia Garza Veloz, Margarita Martínez Fierro, José Manuel Ortiz Rodríguez. **Breast cancer tumor classification using LASSO method selection approach.** XVI International Symposium on Solid State Dosimetry (ISSSD 2016) Proceedings, Volume 3. Tuxtla Gutiérrez, Chis., Mexico. Pp. 260-170.

Como parte de los desarrollos que se realizan al interior del LIDTIA, en este trabajo que corresponde a un estudiante de Pos-Doctorado, se exploran técnicas de minerías de datos tradicionales que servirán para comparar los resultados con técnicas avanzadas empleando RNA con el objetivo de validar las herramientas tecnológicas

4.4. Formación de capital humano

4.4.1. Co-asesoría en tesis de licenciatura

4.4.1.1. *Optimización de la arquitectura de una red neuronal en espectrometría de neutrones para reducir el número de esferas Bonner.*

Nombre de la alumna: León Pérez Ana Alicia

Productos derivados de este proyecto:

8. León-Pérez, A.A.; Martínez-Blanco, M.R.; Hernández-Pérez, C.F.; Espinoza-García, J.G.; Castañeda-Miranda, V.H.; Solis-Sánchez, L.O.; Castañeda-Miranda, R.; Vega-Carrillo, H.R.; Méndez-Villafaña, R.; Gallego, E.; de Sousa Lacerda, M.A.; Ortíz-Rodríguez, J.M. (2016). **Optimización de la arquitectura de una red neuronal en espectrometría de neutrones para reducir el número de esferas Bonner.** XVI International Symposium on Solid State Dosimetry (ISSSD 2016) Proceedings, Volume 3. Tuxtla Gutiérrez, Chis., Mexico. Pp. 217-234.

Este artículo se generó como resultado del trabajo de tesis de esta alumna de licenciatura, cuyo objetivo fundamental fue aplicar la MEDRRNA en la determinación de una arquitectura óptima de RNAPAPI que permitiera estudiar y analizar que aun reduciendo la cantidad de datos de entrada, la red neuronal entrenada era capaz de resolver el problema de la espectrometría de neutrones. Al reducir el número de esferas, se contribuye a la solución de algunos de los problemas que este sistema presenta, reducir el gran volumen del sistema, disminuir el gran peso del mismo y reducir de forma considerable los largos periodos de tiempo requeridos para realizar la lectura de las tasas de conteo en ámbitos experimentales. El desarrollo de la tesis implicó determinar 4 arquitecturas de red para casos de estudio distintos: Caso I – empleando 7 esferas Bonner como datos de entrada, caso II- empleando 2 esferas Bonner como datos de entrada, Caso II - empleando la esfera Bonner de 5 pulgada como único caso de entrada, Caso IV- emplear la esfera Bonner de 8 pulgados como

único dato de entrada. Para realizar lo anterior, para cada arquitectura de red a ser optimizada se entrenaron cerca de 40 distintos tipos de arquitecturas de red.

4.4.1.2. Entrenamiento de redes neuronales de propagación inversa aplicadas a la dosimetría de neutrones.

Nombre del alumno: Hernández Pérez Cruz Felipe

Productos derivados de este proyecto:

9. Hernández-Pérez, C.F.; Martínez-Blanco, M.R.; León-Pérez, A.A.; Espinoza-García, J.G.; Castañeda-Miranda, V.H.; Solis-Sánchez, L.O.; Castañeda-Miranda, R.; Vega-Carrillo, H.R.; Méndez-Villafañe, R.; Gallego, E.; de Sousa Lacerda, M.A.; Ortiz-Rodríguez, J.M. (2016). **Entrenamiento de redes neuronales de propagación inversa aplicada a la dosimetría de neutrones.** XVI International Symposium on Solid State Dosimetry (ISSSD 2016) Proceedings, Volume 3. Tuxtla Gutiérrez, Chis., Mexico. Pp. 235-259.

Este proyecto de tesis de licenciatura se realizó de la misma forma que la anterior. La diferencia principal es que el objetivo en este trabajo se orientó a resolver el problema de la dosimetría de neutrones. Los resultados obtenidos se compararon con los obtenidos en la tesis anterior con el objetivo de analizar las semejanzas y diferencias en cuanto a las arquitecturas de red obtenidas y en el desempeño y la capacidad de generalización de las redes entrenadas, así como en observar si al reducir el número de datos de entrada, la red es capaz de seguir resolviendo el problema para la cual fue entrenada.

4.4.1.3. Espectrometría y dosimetría neutrónica con redes neuronales y esferas Bonner: un estudio para reducir el número de esferas.

Nombre del alumno: Espinoza García J. Guadalupe

Productos derivados de este proyecto:

10. Espinoza-García, J.G.; Martínez-Blanco, M.R.; León-Pérez, A.A.; Hernández-Pérez, C.F.; Castañeda-Miranda, V.H.; Solís-Sánchez, L.O.; Castañeda-Miranda, R.; Vega-Carrillo, H.R.; Méndez-Villafaña, R.; Gallego, E.; de Sousa Lacerda, M.A.; Ortiz-Rodríguez, J.M. (2016). **Espectrometría y dosimetría neutrónica con Redes Neuronales y Esferas Bonner: Un estudio para reducir el número de esferas**. XVI International Symposium on Solid State Dosimetry (ISSSD 2016) Proceedings, Volume 2. Tuxtla Gutiérrez, Chis., Mexico. Pp. 59-71.

Este proyecto de tesis de licenciatura se realizó de la misma forma que las dos anteriores. La diferencia principal es que el objetivo en este trabajo se orientó a resolver el problema de la espectrometría y dosimetría simultánea de neutrones. Los resultados obtenidos se compararon con los obtenidos en las tesis anteriores con el objetivo de analizar las semejanzas y diferencias en cuanto a las arquitecturas de red obtenidas y en el desempeño y la capacidad de generalización de las redes entrenadas, así como en observar si al reducir el número de datos de entrada, la red es capaz de seguir resolviendo el problema para la cual fue entrenada.

4.4.2. Co-asesoría en tesis de maestría

4.4.2.1. Redes Neuronales Artificiales de regresión generalizada en espectrometría y dosimetría de neutrones

Nombre de la tesis: Reyes Alfaro Arturo

El objetivo de esta tesis de maestría fue utilizar el código de deconvolución diseñado en ambientes experimentales reales con el objetivo de ponerlo a prueba. Se pudo observar que es posible reducir el número de esferas Bonner como datos de entrada a la RNARG.

4.5. Registros de derechos de autor

Como parte de los productos obtenidos en la presente tesis doctoral, se diseñó e implemento una metodología para el entrenamiento de RNARG, lo que derivó en el registro de 17 registros de protección de derechos de autor. En base a la metodología anterior, al aplicarlo en el ámbito de la espectrometría y dosimetría neutrónica, se desarrolló también un código de deconvolución de espectros de neutrones denominado NSDGRANN. A continuación, se enlistan los registros de propiedad intelectual realizados.

1. Función que calcula la prueba estadística de chi cuadrada en el entrenamiento de redes neuronales de regresión generalizada.
2. Función que calcula la prueba estadística de chi cuadrada en el entrenamiento de redes neuronales de regresión generalizada aplicadas en dosimetría de neutrones.
3. Función que calcula la prueba estadística de chi cuadrada en el entrenamiento de redes neuronales de regresión generalizada aplicadas en espectrometría de neutrones.
4. Función que almacena los valores de distribución de la prueba estadística de chi cuadrada en el entrenamiento de redes neuronales de regresión generalizada aplicadas en dosimetría de neutrones
5. Función que almacena los valores de distribución de la prueba estadística de chi cuadrada en el entrenamiento de redes neuronales de regresión generalizada aplicadas en espectrometría de neutrones
6. Función que almacena los valores de distribución de la prueba estadística de chi cuadrada en el entrenamiento de redes neuronales de regresión generalizada aplicadas.
7. Función que calcula la correlación en el entrenamiento de redes neuronales de regresión generalizada.
8. Función que calcula la correlación en el entrenamiento de redes neuronales de regresión generalizada aplicadas en dosimetría de neutrones.

9. Función que calcula la correlación en el entrenamiento de redes neuronales de regresión generalizada aplicadas en espectrometría de neutrones.
10. Función que calcula el desempeño en el entrenamiento de redes neuronales de regresión generalizada.
11. Función que realiza el entrenamiento de redes neuronales de regresión generalizada.
12. Función que genera las matrices de entrenamiento-prueba para redes neuronales de regresión generalizada.
13. Función que realiza el análisis de mínimos cuadrados en el entrenamiento de redes neuronales de regresión generalizada.
14. Función que realiza el análisis de mínimos cuadrados en el entrenamiento de redes neuronales de regresión generalizada aplicadas en dosimetría de neutrones.
15. Función que realiza el análisis de mínimos cuadrados en el entrenamiento de redes neuronales de regresión generalizada aplicadas en espectrometría de neutrones.
16. Función principal para el entrenamiento de redes neuronales de regresión generalizada.
17. Función que realiza la etapa de simulación en el entrenamiento de redes neuronales de regresión generalizada.
18. NSDGRANN
19. NSDann 4.0
20. NSDUAZ 2.0
21. Código para graficar espectros de neutrones.
22. Código para entrenar redes neuronales de regresión generalizada.

4.6. Discusión

El actual estado del arte de la espectrometría y dosimetría de neutrones por medio de la tecnología de IA empleando RNA es una técnica muy nueva en este ámbito del

conocimiento. A pesar de los resultados alentadores obtenidos, ha sufrido de una serie de inconvenientes que hacen difícil su aplicación práctica en situaciones experimentales reales, ya que se ha observado que se carece de herramientas científico-tecnológicas que permitan aplicarla de forma ágil y eficiente. Lo anterior ha puesto de manifiesto que la carencia de estas bases, así como la falta de herramientas, hacen necesario abrir una línea de investigación en este dominio del conocimiento. En este sentido se estudió y exploró el uso de las RNE a través del uso de RNARG.

En el ámbito de la IA empleando la tecnología de RNA, existen diferentes métodos para modelar un sistema con datos disponibles. Cada uno tiene cualidades propias y en consecuencia ventajas. Las RNARG caen dentro de la categoría de las RNE. Esta topología de RNA al igual que otros tipos de RNE únicamente necesitan una fracción de las muestras de entrenamiento que podría necesitar una RNAPAPI. Por lo anterior, el uso de las RNARG es especialmente ventajoso debido a su habilidad de converger a la función subyacente de los datos con solamente algunas muestras de entrenamiento disponibles. El conocimiento adicional necesario para obtener el ajuste de forma satisfactoria es relativamente pequeño y se puede realizar sin entradas adicionales por parte del usuario.

Los métodos estadísticos tienden a poner más énfasis en la estructura de los datos. Para los métodos basados en RNA la estructura de los datos es secundaria. Entonces, la cantidad de los datos requeridos por los métodos estadísticos es mucho más pequeña que la cantidad requerida para los métodos basados en RNAPAPI.

La mayoría de los métodos son asintóticamente buenos, sin embargo, la mayoría de ellos también presentan severos inconvenientes. Las RNAPAPI necesitan una gran cantidad de muestras de entrenamiento y emplean una gran cantidad de tiempo para gradualmente obtener buenos valores de los pesos sinápticos. El añadir nueva información a RNA de este tipo de arquitecturas requiere un proceso de re-entrenamiento de las redes lo que resulta muy caro computacionalmente para las RNAPAPI pero no para las RNARG. Las RNARG presentan la ventaja de que el

algoritmo de predicción trabaja con pocas muestras de entrenamiento. La otra ventaja es que son sumamente flexibles y que se puede añadir nueva información de forma inmediata casi sin requerir re-entrenar a la RNA.

Las RNARG emplean un método estadístico en su algoritmo de predicción. Las bases de este método están dadas en la estrategia de Bayes para el reconocimiento de patrones [34]. Estas estrategias se pueden aplicar a problemas que contienen cualquier número de categorías como es el caso de los problemas relacionados con la espectrometría y dosimetría de neutrones. Para ser capaz de utilizar la estrategia de Bayes es necesario estimar con precisión la función de probabilidad de densidad. La única información disponible para estimar esta función son las muestras de entrenamiento.

La estructura de los cálculos para esta función tiene sorprendentes similitudes con las redes del tipo RNAPAPI. Las RNARG se utilizan con frecuencia para la clasificación de patrones en base al aprendizaje a partir de ejemplos y se basan en el algoritmo de la estrategia de Bayes para la clasificación de patrones. Diferentes reglas determinan la estadística de patrones a partir de las muestras de entrenamiento. Las RNAPAPI utilizan métodos que no se basan en métodos estadísticos por lo que requieren largos periodos de tiempo y muchas iteraciones y realimentaciones hasta que gradualmente se aproximan a la función subyacente. Por otro lado, la estrategia de Bayes extrae las características a las muestras de entrenamiento para llegar al conocimiento de la función subyacente.

Las RNRG tienen una estructura simple y en consecuencia procedimientos sumamente estables. Este tipo de redes se desempeñan muy bien empleando pocas muestras de entrenamiento y la calidad se incrementa a medida que se incrementa el número de muestras de entrenamiento. Esto hace a las RNARG una herramienta tecnológica prometedora que se puede aplicar para resolver con alta efectividad en los problemas relacionados con la espectrometría y dosimetría neutrónica y los de otras disciplinas de ciencia e ingeniería.

La estrategia de diseño de arquitecturas de RNA en el ámbito de la espectrometría neutrónica, por su naturaleza y complejidad, implicó que para resolver el problema planteado fuera necesario dividirlo en múltiples etapas, entre las cuales se pueden destacar las siguientes:

1. Pre-procesamiento de la información en el proceso de creación de las matrices de entrenamiento a ser utilizadas en las etapas del entrenamiento de las redes a ser diseñadas.
2. El empleo de dos metodologías sistemáticas aplicadas en la determinación de los parámetros óptimos de las redes a ser entrenadas: MDRRNA y RNE. El empleo de las herramientas citadas permitió reducir el tiempo empleado en la selección de los parámetros de las arquitecturas de RNA de meses a minutos.
3. El proceso de extracción del conocimiento de las redes diseñadas y la creación de un conjunto de códigos para la reconstrucción de espectros de neutrones basado en este conocimiento, diseñados para un SEEB basado en un detector de ${}^6\text{Li}(\text{Eu})$ y un SEEB basado en un detector de ${}^3\text{He}$. Las herramientas diseñadas hicieron posible aplicar de forma efectiva, rápida y enciente la tecnología de RNA en el ámbito de la espectrometría neutrónicas, resolviendo muchos de los problemas asociados con las herramientas clásicas empleadas en la actualidad.
4. El diseño y desarrollo de una herramienta de cómputo que permite intercomparar de forma gráfica, numérica y estadística los resultados obtenidos con las herramientas diseñadas en el punto anterior. Esta herramienta permitió realizar un análisis de los resultados obtenidos, de forma fácil, rápida y enciente a través del entorno gráfico diseñado.
5. El diseño y desarrollo de un algoritmo basado en la estadística de Poisson, implementado en las herramientas desarrolladas en el punto anterior, para cuantificar la incertidumbre asociada con las tasas de conteo medidas con los SEEB utilizados para la espectrometría neutrónica. Las herramientas clásicas no cuantifican las incertidumbres asociadas con el uso del SEEB. Esta rutina permite cuantificar el error asociado con las tasas de conteo del SEEB.

6. Aplicar las herramientas desarrolladas en ambientes experimentales reales, observado su rendimiento y desempeño. Por las características de diseño de las topologías de RNA diseñadas por otros investigadores, resulta muy complicado aplicarlas en situaciones experimentales reales si no se cuenta con bases sólidas en el ámbito de la teoría de RNA y en el entorno de ambiente de programación de Matlab, lo que representa un serio inconveniente. Las herramientas desarrolladas se ajustan al ambiente experimental por ser autónomas de cualquier programa y ser fáciles, rápidas y eficientes en su uso por parte de cualquier persona.
7. Comparar los resultados obtenidos con las herramientas diseñadas contra los obtenidos con códigos tradicionales empleados en la actualidad por los distintos laboratorios. Por las características de diseño de las herramientas mencionadas fue posible realizar múltiples experimentos en la medición de fuentes de neutrones bajo distintas condiciones y comparar los resultados contra los obtenidos con las metodologías clásicas, observando que las herramientas diseñadas ofrecen ventajas significativas en cuanto a la facilidad de uso, rendimiento, velocidad de cálculo y manipulación de información.

Conclusiones

La reconstrucción de espectros de neutrones y el cálculo de dosis equivalentes mediante RNA a partir de las tasas de conteo del SEBB, es una técnica alternativa que ha recibido gran atención durante los últimos años debido a los exitosos resultados que se han obtenido, mismos que resuelven muchos de los problemas antes mencionados cuando se aplican las técnicas clásicas.

En trabajos anteriores, utilizando MDRRNA se ha diseñado una gran variedad de arquitecturas y topologías del tipo RNAPAPI con el objetivo de construir una herramienta computacional basada en esta tecnología que tuviera la capacidad de resolver los problemas asociados con la EDN. Sin embargo, una RNARG presenta diferencias cuando se compara con la RNAPAPI. El aprendizaje de estas últimas se puede describir como un proceso de prueba y error. Este no es el caso de las RNARG debido a que utilizan un método estadístico en el algoritmo de predicción, capaz de trabajar con pocas muestras de entrenamiento. La experiencia no se adquiere o se aprende a través del ensayo sino a través de la experiencia que otros realizaron (datos de entrenamiento). Las RNARG son muy flexibles por lo que se puede añadir nueva información inmediatamente casi no siendo requerido el reentrenamiento. La mayor ventaja es el hecho de que el método probabilístico de las RNARG trabaja con un aprendizaje de un solo paso.

Una diferencia mayor que existe entre las RNAPAPI y las RNARG es la diferencia en los procesos que ocurren dentro de las neuronas. Una RNARG utiliza funciones que se basan en el conocimiento que resulta de la clasificación de patrones del teorema de Bayes. La estructura de los cálculos de la función de densidad probabilística en las RNARG tiene sorprendentes similitudes con las RNAPAPI. La fuerza de una RNARG radica en la función que se utiliza dentro de la neurona.

En el caso de la solución de problemas de ingeniería empleando la tecnología de RNA, sería deseable determinar los parámetros óptimos de entrenamiento utilizando un método de un solo paso. La estrategia de Bayes para la clasificación de patrones extrae las características a partir de las muestras de entrenamiento para llegar al conocimiento de la función subyacente.

En el presente proyecto de tesis doctoral, se realizó el estudio, análisis, diseño, implementación y automatización de una metodología para el entrenamiento de RNARG con aplicación en espectrometría y dosimetría neutrónica. También se realizó el desarrollo de un código de deconvolución de espectros de neutrones basado en la metodología previamente mencionada. Para validar la herramienta tecnológica diseñada, se comparó el desempeño obtenido empleando las RNAPAPI frente al obtenido con las RNARG. Los resultados obtenidos al realizar lo mencionado, fueron documentados y publicados en forma de capítulos de libro y artículos indizados como se detalla en la sección de resultados y anexos.

De lo expuesto a lo largo del presente documento, se puede concluir que se alcanzaron los objetivos generales planteados en la sección 1, esto es, el estudio, análisis, diseño y aplicación de RNARG capaces de resolver con alto rendimiento y capacidad de generalización los problemas relacionados con la espectrometría y dosimetría de neutrones.

También se cumplió el segundo objetivo: el diseño de herramientas tecnológicas que permiten aplicar de forma eficiente, fácil y rápida el conocimiento adquirido por las redes diseñadas, en ambientes laborales, experimentales, y de laboratorio.

El código NSDGRANN presenta las siguientes características:

-) Se creó en un entorno gráfico ejecutable en el ambiente de programación de Matlab, por lo que opera de forma independiente al entorno mismo de programación.
-) Cuenta con una forma eficiente de entrada y salida de datos.
-) Es fácil de utilizar.
-) Se ejecuta de forma rápida, obteniendo los resultados en cuestión de segundos.
-) Para la operación de la herramienta computacional, no es indispensable para el usuario el que cuente con conocimientos de espectrometría o dosimetría de neutrones, así como de redes neuronales.
-) A diferencia de los códigos utilizados en la actualidad, los cuales están basados en algoritmos de reconstrucción iterativos, mismos que requieren para la deconvolución del espectro un usuario experto, así como información “a priori” (espectro inicial) para la operación de las herramientas diseñadas, en este trabajo no es necesaria tal información, ya que únicamente requiere como datos de entrada, las tasas de conteo provenientes del SEEB, además de las ventajas ya mencionadas.

A diferencia de las herramientas de cómputo tradicionales basadas en códigos de reconstrucción iterativos, la deconvolución del espectro de neutrones y el cálculo de dosis, a partir del código de reconstrucción de espectros de neutrones denominado NSDGRANN, basado en la tecnología de RNARG, se realiza de forma rápida, fácil y eficiente. No existe la imperiosa necesidad de proporcionar al programa información “a priori” o algún parámetro, a excepción de las tasas de conteo tomadas a partir de un SEEB. El resultado se obtiene en cuestión de segundos, pudiendo almacenarse los valores calculados para un análisis posterior y continuar de forma inmediata con la

reconstrucción de un número ilimitado de espectros de neutrones. Por sus características de diseño, esta herramienta resulta práctica en ambientes experimentales reales.

Otra característica importante de las herramientas creadas, es que fueron diseñadas para que el usuario final las encuentre fáciles de utilizar, sin importar la complejidad que puedan tener las rutinas de programación que componen a los códigos, evitando lo más posible que para su uso, el usuario cuente con conocimientos científicos y/o técnicos muy especializados en las áreas de espectrometría neutrónica y/o redes neuronales artificiales, en las cuales están basadas, como sucede con las herramientas clásicas actualmente utilizadas en los laboratorios de este tipo y que representa un serio inconveniente.

Las herramientas se diseñaron de tal forma que para comodidad del usuario, los códigos comparten características similares en lo que se refiere al entorno gráfico y en la forma de trabajar con los programas. Lo anterior propicia que al aprender a utilizar una herramienta, se está en condiciones de utilizar las otras en una cantidad mínima de tiempo, debido a las similitudes de diseño que comparten. Esto, a diferencia de las herramientas clásicas basadas en entornos de consola MS-DOS, permite ahorrar tiempo en el proceso de aprendizaje y permite de igual forma aplicarlas de manera inmediata en ambientes experimentales reales.

5.1. Prospectivas

Algunas de las posibilidades previstas para eficientar el desempeño de la herramienta diseñada, se consideran las siguientes:

1. Estandarizar los datos. En el análisis de datos es necesario estandarizar los conjuntos de datos antes de realizar cualquier cálculo. Uno de los métodos de estandarización más utilizados es formar todas las variables en varianzas unitarias y medias cero. Para realizarlo, se resta la media o valor esperado y se

divide por la desviación estándar. El primer paso “Centra” la variable o el dato dándole una media cero y el segundo paso expresa la variable o dato en términos de números de desviación estándar de la media. La transformación se realiza utilizando la ecuación 13.

$$X^* = \frac{X-\mu}{\sigma} \quad (13)$$

En donde μ es la media y σ es la desviación estándar, X son las tasas de conteo de los datos de entrada y los espectros, dosis e instrumentos de los datos de salida, mientras que X^* es el valor estandarizado.

En este trabajo se estandarizaron todos los valores tanto de las entradas como de las salidas de tal forma que las variables resultantes tienen una varianza unitaria y una media cero. En el proceso de estandarización, todas las variables se transformaron y el resultado muestra una mejor distribución.

El proceso de estandarización es importante porque hace que cada variable juegue el mismo rol que las otras, pudiendo reducir los errores de predicción dados por la RNA.

2. Aplicar la técnica de validación cruzada Leave-one-out para validar el valor óptimo de la constante de propagación para el entrenamiento de la RNARG, la cual selecciona una única observación a partir de la muestra original y la mantiene como el dato a validar, y utiliza las observaciones restantes como los datos de entrenamiento. El *kernel de propagación constante* se seleccionará de igual forma en el rango de 0 a 2 en pasos de 0.01.
3. La selección etiquetada como “Otros” en la figura 3.10 permita realizar entrenamientos de RNARG en la solución de problemas de ingeniería distintos al de la espectrometría neutrónica. Al seleccionar esta opción, la herramienta

computacional pedirá al usuario final ingresar los datos correspondientes a las matrices de datos de entrenamiento tanto de entrada como de salida.

4. El código de deconvolución en cuestión permite seleccionar tres matrices de respuesta y dentro de ésta el número de esferas Bonner con los que se realiza el entrenamiento de las RNA. El código tiene la capacidad de reconstruir espectros de neutrones, calcular 15 cantidades dosimétricas. Se proyecta que en un futuro sea capaz de estimar de forma simultánea las lecturas que podrían ser tomadas con 8 instrumentos de medición.

Bibliografía

- [1] S. J. Russel y P. Norvig, *Inteligencia Artificial. Un Enfoque Moderno*, 2a ed. Madrid, España: Prentice Hall, 2004.
- [2] B. Apolloni y S. B. and M. Marinaro, *New Directions in Neural Networks: 18th Italian Workshop on Neural Networks: WIRN 2008 - Volume 193 Frontiers in Artificial Intelligence and Applications*. Amsterdam; Washington, DC: IOS Press, 2009.
- [3] B. Coppin, *Artificial Intelligence Illuminated*, Computer ed. edition. Boston: Jones & Bartlett Learning, 2004.
- [4] P. Fritzsche, Ed., *Tools in Artificial Intelligence*. InTech, 2008.
- [5] D. Graupe, *Principles of Artificial Neural Networks*. Singapore; River Edge, NJ: World Scientific Publishing Company, 1997.
- [6] C. L. P. Hui, Ed., *Artificial Neural Networks - Application*. InTech, 2011.
- [7] R. Chiong, *Nature-Inspired Informatics for Intelligent Applications and Knowledge Discovery: Implications in Business, Science, and Engineering*. IGI Global, 2001.
- [8] E. Bonabeau, M. Dorigo, y G. Theraulaz, *Swarm Intelligence: From Natural to Artificial Systems*. OUP USA, 1999.
- [9] D. Wicker, M. M. Rizki, y L. A. Tamburino, "E-Net: Evolutionary neural network synthesis", *ResearchGate*, vol. 42, núm. 1–4, pp. 171–196, ene. 2002.
- [10] C. R. Alavala, *Fuzzy Logic and Neural Networks: Basic Concepts and Applications*. New Delhi: New Age International Pvt Ltd Publishers, 2008.
- [11] N. K. Kasabov, *Foundations of Neural Networks, Fuzzy Systems, and Knowledge Engineering*. Cambridge, Mass: The MIT Press, 1996.
- [12] C. J. Lakhmi, *Fusion of Neural Networks, Fuzzy Systems and Genetic Algorithms: Industrial Applications*. CRC Press, 1998.
- [13] M. Gen, O. Katai, B. McKay, A. Namatame, R. A. Sarker, y B.-T. Zhang, Eds., *Intelligent and Evolutionary Systems*, 2009 edition. Berlin: Springer, 2009.
- [14] C. S. Krishnamoorthy y S. Rajeev, *Artificial Intelligence and Expert Systems for Engineers*, 1 edition. Boca Raton: CRC Press, 1996.
- [15] S. Russell y P. Norvig, *Artificial Intelligence: A Modern Approach*, 3 edition. Upper Saddle River: Pearson, 2009.
- [16] D. Floreano y C. Mattiussi, *Bio-Inspired Artificial Intelligence: Theories, Methods, and Technologies*. Cambridge, Mass: Intelligent Robotics and Auton, 2008.
- [17] F. H. Attix, *Introduction to Radiological Physics and Radiation Dosimetry*, Edición: 1. New York: John Wiley & Sons Inc, 1991.
- [18] R. Bedogni, "Neutron spectrometry and dosimetry for radiation protection around a high energy electron / positron collider", *Universitat Autònoma de Barcelona*, 2006.
- [19] D. J. Thomas, "Neutron spectrometry for radiation protection", *Radiat. Prot. Dosimetry*, vol. 110, núm. 1–4, pp. 141–149, 2004.
- [20] F. D. Brooks y H. Klein, "Neutron spectrometry--historical review and present status", *Nucl. Instrum. Methods Phys. Res. Sect. Accel. Spectrometers Detect. Assoc. Equip.*, vol. 476, núm. 1–2, pp. 1–11, 2002.

- [21] I. Ionita, "Focusing conditions in neutron spectrometry", *ResearchGate*, vol. 489, núm. 1, pp. 313–336, ago. 2002.
- [22] "Neutron spectrometry for radiation protection. - PubMed - NCBI". [En línea]. Disponible en: <https://www.ncbi.nlm.nih.gov/pubmed/15353637>. [Consultado: 10-nov-2016].
- [23] R. L. Bramblett, R. I. Ewing, y T. W. Bonner, "A new type of neutron spectrometer", *Nucl. Instrum. Methods*, vol. 9, núm. 1, pp. 1–12, oct. 1960.
- [24] M. Tomás, F. Fernández, M. Bakali, y H. Muller, "MITOM: a new unfolding code based on a spectra model method applied to neutron spectrometry", *Radiat. Prot. Dosimetry*, vol. 110, núm. 1–4, pp. 545–548, 2004.
- [25] R. Bedogni, C. Domingo, A. Esposito, y F. Fernández, "FRUIT: An operational tool for multisphere neutron spectrometry in workplaces", *Nucl. Instrum. Methods Phys. Res. Sect. Accel. Spectrometers Detect. Assoc. Equip.*, vol. 580, núm. 3, pp. 1301–1309, oct. 2007.
- [26] K. O'Brien y R. Sanna, "Neutron spectral unfolding using the Monte Carlo method", *Nucl. Instrum. Methods Phys. Res.*, vol. 185, núm. 1, pp. 277–286, jun. 1981.
- [27] G. Simmer, V. Mares, E. Weitzenegger, y W. Rühm, "Iterative unfolding for Bonner sphere spectrometers using the MSANDB code – Sensitivity analysis and dose calculation", *Radiat. Meas.*, vol. 45, núm. 1, pp. 1–9, Enero 2010.
- [28] C. Su y T. K. Sarkar, "A Multiscale Moment Method for Solving Fredholm Integral Equation of the First Kind - Summary", *J. Electromagn. Waves Appl.*, vol. 12, núm. 1, pp. 97–101, Enero 1998.
- [29] M. Matzke y K. Weise, "Neutron spectrum unfolding by the Monte Carlo method", *Nucl. Instrum. Methods Phys. Res. Sect. Accel. Spectrometers Detect. Assoc. Equip.*, vol. 234, núm. 2, pp. 324–330, feb. 1985.
- [30] J. M. Ortiz-Rodríguez et al., "Evaluating the Performance of Two Neutron Spectrum Unfolding Codes Based on Iterative Procedures and Artificial Neural Networks", *ResearchGate*, vol. 1544, núm. 1, pp. 114–121, jul. 2013.
- [31] A. V. Alevra, M. Cosack, J. B. Hunt, D. J. Thomas, y H. Schraube, "Experimental Determination of the Response of Four Bonner Sphere Sets to Monoenergetic Neutrons (II)", *Radiat. Prot. Dosimetry*, vol. 40, núm. 2, pp. 91–102, feb. 1992.
- [32] E. N. Hertel y J. W. Davidson, "The response of bonner spheres to neutrons from thermal energies to 17.3 MeV", *Nucl. Instrum. Methods Phys. Res. A*, vol. 238, pp. 509–516, 1985.
- [33] M. Wielunski, W. Wahl, N. EL-Faramawy, W. Rühm, M. Luszik-Bhadra, y H. Roos, "Intercomparison exercise with MeV neutrons using various electronic personal dosimeters", *Radiat. Meas.*, vol. 43, núm. 2–6, pp. 1063–1067, feb. 2008.
- [34] M. Reginatto y A. Zimbal, "Bayesian and maximum entropy methods for fusion diagnostic measurements with compact neutron spectrometers", *Rev. Sci. Instrum.*, vol. 79, núm. 2, p. 23505, feb. 2008.
- [35] S. Itoh, "A fundamental study of neutron spectra unfolding based on the maximum likelihood method", *Nucl. Instrum. Methods Phys. Res. Sect. Accel. Spectrometers Detect. Assoc. Equip.*, vol. 251, núm. 1, pp. 144–155, oct. 1986.
- [36] J. M. Ortiz-Rodríguez et al., "Neutron spectrometry using artificial neural networks for a bonner sphere spectrometer with a ^3He detector", *Rev. Mex. Física*, vol. 57, pp. 69–71, feb. 2011.
- [37] S. Avdic, S. A. Pozzi, y V. Protopopescu, "Detector response unfolding using artificial neural networks", *Nucl. Instrum. Methods Phys. Res. Sect. Accel. Spectrometers Detect. Assoc. Equip.*, vol. 565, núm. 2, pp. 742–752, sep. 2006.
- [38] J. M. Ortiz-Rodríguez, R. Martínez-Blanco, E. Gallego, y H. R. Vega-Carrillo, "Neutron spectrometry and dosimetry based on a new approach called Genetic Artificial Neural Networks", 2010.

- [39] A. Sharghi Ido, M. R. Bonyadi, G. R. Etaati, y M. Shahriari, "Unfolding the neutron spectrum of a NE213 scintillator using artificial neural networks", *Appl. Radiat. Isot.*, vol. 67, núm. 10, pp. 1912–1918, oct. 2009.
- [40] *Artificial Intelligence Applications and Innovations - | Harris Papadopoulos | Springer.*
- [41] G. Weiss, Ed., *Multiagent Systems: A Modern Approach to Distributed Artificial Intelligence*, New Ed edition. Cambridge, Mass.: The MIT Press, 2000.
- [42] M. Gen y R. Cheng, *Genetic Algorithms and Engineering Optimization*, 1 edition. New York: Wiley-Interscience, 1999.
- [43] D. F. Specht, "Probabilistic neural networks for classification, mapping, or associative memory", en *ResearchGate*, 1988, vol. 1, pp. 525–532 vol.1.
- [44] H. R. Vega-Carrillo, V. M. Hernández-Dávila, E. Manzanares-Acuña, G. A. Mercado-Sánchez, T. Arteaga-Arteaga, y J. M. Ortiz-Rodríguez, "Neutron Spectra Unfolding with Artificial Neural Networks", *Encuentro Investig. En Ing. Eléctrica ENINVIE 2005*, pp. 132–139, mar. 2005.
- [45] H. R. Vega-Carrillo et al., "Neutron spectrometry using artificial neural networks", *Radiat. Meas.*, vol. 41, núm. 4, pp. 425–431, Abril 2006.
- [46] J. M. Ortiz R, M. R. Martínez B, y H. R. Vega C, "RDANN a new methodology to solve the neutron spectra unfolding problem", *IX Int. Symp. Natl. Meet. Solid State Dosim.*, pp. 215–220, sep. 2006.
- [47] G. F. Luger, *Artificial Intelligence: Structures and Strategies for Complex Problem Solving*, 6 edition. Boston: Pearson, 2008.
- [48] D. F. Specht, "Probabilistic Neural Networks", *Neural Netw*, vol. 3, núm. 1, pp. 109–118, ene. 1990.
- [49] IAEA, *Neutron Monitoring for Radiological Protection. Technical Report Series No. 252.* 1985.
- [50] K. Y. Lee y M. A. El-Sharkawi, *Modern Heuristic Optimization Techniques: Theory and Applications to Power Systems*, Edición: 1. Piscataway, N.J. : Hoboken, N.J: Ieee Press Series on Power Eng, 2008.
- [51] M. Gendreau y J.-Y. Potvin, *Handbook of Metaheuristics*, Edición: 2010. New York: Springer, 2010.
- [52] P. Baldi y S. Brunak, *Bioinformatics: The Machine Learning Approach*, 2 edition. A Bradford Book, 2001.
- [53] S. Whiteson y P. Stone, "Evolutionary Function Approximation for Reinforcement Learning", *J Mach Learn Res*, vol. 7, pp. 877–917, Diciembre 2006.
- [54] J. A. Freeman y D. M. Skapura, *Neural Networks: Algorithms, Applications and Programming Techniques*, Edición: First Printing. Reading, Mass: Addison Wesley, 1991.
- [55] M. Negnevitsky, *Artificial Intelligence: A Guide to Intelligent Systems*, 2 edition. Harlow, England; New York: Addison-Wesley, 2004.
- [56] M. Kusy y J. Kluska, "Probabilistic Neural Network Structure Reduction for Medical Data Classification", en *Artificial Intelligence and Soft Computing*, L. Rutkowski, M. Korytkowski, R. Scherer, R. Tadeusiewicz, L. A. Zadeh, y J. M. Zurada, Eds. Springer Berlin Heidelberg, 2013, pp. 118–129.
- [57] R. P. Lippmann, "An Introduction to Computing with Neural Nets", *ResearchGate*, vol. 4, núm. 2, pp. 4–22, may 1987.
- [58] M. A. Arbib, *Brain Theory and Neural Networks*, Edición: 00002. Cambridge, Mass: Bradford Books, 2002.
- [59] S. Haykin, *Neural Networks - A Comprehensive Foundation - Simon Haykin.pdf*, 2a ed. Pearson Education, 2001.
- [60] J. Zupan, "Introduction to Artificial Neural Networks (ANN) Methods: What they are and how to use them", *Acta Chim. Slov.*, vol. 41, núm. 3, pp. 327–352, 1994.

- [61] A. K. Jain, J. Mao, y K. M. Mohiuddin, "Artificial Neural Networks: A Tutorial", *ResearchGate*, vol. 29, núm. 3, pp. 31–44, abr. 1996.
- [62] L. C. Jain y A. M. Fanelli, Eds., *Recent Advances in Artificial Neural Networks: Design and Applications*, 1 edition. Boca Raton: CRC Press, 2000.
- [63] M. M. Gupta, N. Homma, y L. Jin, *Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory*, 1st ed. New York, NY, USA: John Wiley & Sons, Inc., 2003.
- [64] D.-S. Huang, "Radial basis probabilistic neural networks: model and application", *Int. J. Pattern Recognit. Artif. Intell.*, vol. 13, núm. 7, pp. 1083–1101, nov. 1999.
- [65] K. Z. Mao, K.-C. Tan, y W. Ser, "Probabilistic Neural-network Structure Determination for Pattern Classification", *Trans Neur Netw*, vol. 11, núm. 4, pp. 1009–1016, jul. 2000.
- [66] F. Vicino, "The Probabilistic Neural Network", *Subst. Use Misuse*, vol. 33, núm. 2, pp. 335–352, ene. 1998.
- [67] D. F. Specht y P. D. Shapiro, "Generalization accuracy of probabilistic neural networks compared with backpropagation networks", en *IJCNN-91-Seattle International Joint Conference on Neural Networks*, 1991, vol. i, pp. 887–892 vol.1.
- [68] J. G. Taylor, Ed., *Mathematical Approaches to Neural Networks*. Amsterdam ; New York: Elsevier Science Ltd, 1993.
- [69] D. F. Specht, "Enhancements to probabilistic neural networks", en *ResearchGate*, 1992, vol. 1, pp. 761–768 vol.1.
- [70] A. Bhattacharya, A. Abraham, P. Vasant, y C. Grosan, "Evolutionary artificial neural network for selecting flexible manufacturing systems under disparate level-satisfaction for decision maker", *Int. J. Innov. Comput. Inf. Control*, vol. 3, núm. 1, pp. 131–140, 2007.
- [71] IAEA, *Compendium of Neutron Spectra in Criticality Accident Dosimetry*. Technical Report Series No. 180. 1978.
- [72] IAEA, *Compendium of Neutron Spectra and Detector Responses for Radiation Protection Purposes*. Technical Report Series No. 318. Austria: IEAE, 2001.
- [73] D. A. Bromley, *Detectors in Nuclear Science*. North Holland Publishing Company, 1979.
- [74] J.-L. Basdevant, J. Rich, y M. Spiro, *Fundamentals in Nuclear Physics: From Nuclear Structure to Cosmology*, Edición: 2005. New York: Springer, 2005.
- [75] R. L. Murray, A. T. Murphy, y D. I. Rosenthal, *Nuclear Energy: An Introduction to the Concepts, Systems, and Applications of Nuclear Processes*, 2nd edition. Oxford ; New York: Pergamon, 1980.
- [76] J. Lilley, *Nuclear Physics: Principles and Applications*, 1 edition. Chichester ; New York: Wiley, 2001.
- [77] R. A. Carrigan, *Non-accelerator Astroparticle Physics: Proceedings of the Sixth School: ICTP, Trieste, Italy, 9-20 July 2001*. CRC Press, 2002.
- [78] H. V. Klapdor-Kleingrothaus y A. Staudt, *Non-Accelerator Particle Physics*. CRC Press, 1998.
- [79] H. Cember y T. E. Johnson, *Introduction to Health Physics: Fourth Edition - Health-Physics-by-Herman-Cember.pdf*, 4a ed. McGraw-Hill, 2009.
- [80] M. Bakali, *Espectrometría neutrónica en las centrales nucleares mediante un sistema de esferas Bonner*. Universitat Autònoma de Barcelona, 2003.
- [81] J. M. Ortiz-Rodríguez, M. del R. Martínez-Blanco, E. Gallego, y H. R. Vega-Carillo, "Artificial Neural Networks Modeling Evolved Genetically, a New Approach Applied in Neutron Spectrometry and Dosimetry Research Areas", en *ResearchGate*, 2008, pp. 387–392.
- [82] J. M. Ortiz-Rodríguez, "Diseño robusto de redes neuronales artificiales aplicadas a la espectrometría de neutrones", *Universidad Autónoma de Zacatecas, Zacatecas, México*, 2005.
- [83] G. F. Knoll, *Radiation Detection and Measurement*. John Wiley & Sons, 2010.

- [84] L. Mackovicka, "Contribution à la dosimétrie neutron-gamma: Etude d'un ensemble radiateur-détecteur type CR 39", Université de Limoges, 1987.
- [85] J. B. Marion y J. L. Fowler, *Fast Neutron Physics. Part 1 & 2. Techniques.*, vol. 132. New York: Interscience, 1960.
- [86] R. S. Caswell, "Fast Neutron Physics. Part 1. Techniques. J. B. Marion and J. L. Fowler, Eds. Interscience, New York, 1960. xiv + 983 pp. Illus. \$29", *Science*, vol. 132, núm. 3427, pp. 613–614, sep. 1960.
- [87] J. B. Marion y J. L. Fowler, *Fast Neutron Physics. Part 1 & 2. Techniques.*, vol. 132. New York: Interscience, 1960.
- [88] R. B. Murray, "Use of LiI(Eu) as a scintillation detector and spectrometer for fast neutrons".
- [89] G. Grosshoeg, "Neutron ionization chambers", *Nucl. Instrum. Methods*, vol. 162, núm. 1, pp. 125–160, jun. 1979.
- [90] J. A. Harvey y N. W. Hill, "Scintillation detectors for neutron physics research", *Nucl. Instrum. Methods*, vol. 162, núm. 1, pp. 507–529, jun. 1979.
- [91] R. E. Apfel, "The superheated drop detector", *Nucl. Instrum. Methods*, vol. 162, núm. 1, pp. 603–608, jun. 1979.
- [92] S. C. Miller, "AFITBUNKI: A Modified Iterative Code to Unfold Neutron Spectra from Bonner Sphere Detector Data", 1993.
- [93] B. Mukherjee, "ANDI-03: a genetic algorithm tool for the analysis of activation detector data to unfold high-energy neutron spectra", *Radiat. Prot. Dosimetry*, vol. 110, núm. 1–4, pp. 249–254, 2004.
- [94] G. Fehrenbacher et al., "Proposal of a New Method for Neutron Dosimetry Based on Spectral Information Obtained by Application of Artificial Neural Networks", *Radiat. Prot. Dosimetry*, vol. 83, núm. 4, pp. 293–301, jul. 1999.
- [95] E. Cordes et al., "An approach to unfold the response of a multi-element system using an artificial neural network", en *Fourth European Conference on Radiation and Its Effects on Components and Systems*, 1997. RADECS 97, 1997, pp. 271–276.
- [96] C. C. Braga y M. S. Dias, "Application of Neural Networks for unfolding neutron spectra measured by means of Bonner Spheres", *Nucl. Instrum. Methods Phys. Res. Sect. Accel. Spectrometers Detect. Assoc. Equip.*, vol. 476, núm. 1–2, pp. 252–255, Enero 2002.
- [97] M. R. Kardan, S. Setayeshi, R. Koohi-Fayegh, y M. Ghiassi-Nejad, "Neutron spectra unfolding in Bonner spheres spectrometry using neural networks", *Radiat. Prot. Dosimetry*, vol. 104, núm. 1, pp. 27–30, 2003.
- [98] M. R. Kardan, R. Koohi-Fayegh, S. Setayeshi, y M. Ghiassi-Nejad, "Fast neutron spectra determination by threshold activation detectors using neural networks", *Radiat. Meas.*, vol. 38, núm. 2, pp. 185–191, Abril 2004.
- [99] H. R. V. Carrillo, B. W. Wehring, K. G. Veinot, y N. E. Hertel, "Response Matrix for a Multisphere Spectrometer using a 6LiF Thermoluminescence Dosimeter", *Radiat. Prot. Dosimetry*, vol. 81, núm. 2, pp. 133–139, ene. 1999.
- [100] M. Matzke, "Unfolding procedures", *Radiat. Prot. Dosimetry*, vol. 107, núm. 1–3, pp. 155–174, nov. 2003.
- [101] V. Lacoste, M. Reginatto, B. Asselineau, y H. Muller, "Bonner sphere neutron spectrometry at nuclear workplaces in the framework of the EVIDOS project", vol. 125 (1–4), pp. 304–308, 2007.
- [102] J. Sweezy, N. Hertel, y K. Veinot, "BUMS—Bonner sphere Unfolding Made Simple: an HTML based multisphere neutron spectrometer unfolding package", *Nucl. Instrum. Methods Phys. Res. Sect. Accel. Spectrometers Detect. Assoc. Equip.*, vol. 476, núm. 1–2, pp. 263–269, Enero 2002.

- [103]B. Mukherjee, "A high-resolution neutron spectra unfolding method using the Genetic Algorithm technique", *Nucl. Instrum. Methods Phys. Res. A*, vol. 476, pp. 247–251, Enero 2002.
- [104]H. R. Vega-Carrillo, V. M. Hernández-Dávila, E. Manzanares-Acuña, E. Gallego, A. Lorente, y M. P. Iñiguez, "Artificial neural networks technology for neutron spectrometry and dosimetry", *Radiat. Prot. Dosimetry*, vol. 126, núm. 1–4, pp. 408–412, ago. 2007.
- [105]A. V. Alevra y V. D. Plostinaru, "Characterisation of the IPNE Bonner sphere spectrometer by comparison with the PTB system", *Nucl. Instrum. Methods Phys. Res. Sect. Accel. Spectrometers Detect. Assoc. Equip.*, vol. 476, núm. 1–2, pp. 21–25, Enero 2002.
- [106]A. V. Alevra y V. D. Plostinaru, "Characterisation of the IPNE Bonner sphere spectrometer by comparison with the PTB system", *Nucl. Instrum. Methods Phys. Res. Sect. Accel. Spectrometers Detect. Assoc. Equip.*, vol. 476, núm. 1–2, pp. 21–25, Enero 2002.
- [107]R. L. Bramblett, R. I. Ewing, y T. W. Bonner, "A new type of neutron spectrometer", *Nucl. Instrum. Methods*, vol. 9, núm. 1, pp. 1–12, oct. 1960.
- [108]D. A. Chambless y J. A. Broadway, "Comments on 'neutron spectral unfolding using the Monte Carlo method'", *Nucl. Instrum. Methods Phys. Res.*, vol. 214, pp. 543–545, sep. 1983.
- [109]B. R. L. Siebert, "Assessment of sensitivities and uncertainties in Monte Carlo particle transport calculations for neutron spectrometry", *Nucl. Instrum. Methods Phys. Res. Sect. Accel. Spectrometers Detect. Assoc. Equip.*, vol. 476, núm. 1–2, pp. 256–262, Enero 2002.
- [110]T. Bouassoule et al., "Monte Carlo calculations and experimental calibrations of Bonner sphere systems with a new cylindrical helium-3 proportional counter", *Radiat. Meas.*, vol. 34, núm. 1–6, pp. 199–202, jun. 2001.

Apéndices

PUBLISHED BY

INTECH

open science | open minds

World's largest Science,
Technology & Medicine
Open Access book publisher



2,850+
OPEN ACCESS BOOKS



97,000+
INTERNATIONAL
AUTHORS AND EDITORS



91+ MILLION
DOWNLOADS



BOOKS
DELIVERED TO
151 COUNTRIES

AUTHORS AMONG
TOP 1%
MOST CITED SCIENTIST



12.2%
AUTHORS AND EDITORS
FROM TOP 500 UNIVERSITIES



Selection of our books indexed in the
Book Citation Index in Web of Science™
Core Collection (BKCI)

Chapter from the book *Artificial Neural Networks - Models and Applications*
Downloaded from: <http://www.intechopen.com/books/artificial-neural-networks-models-and-applications>

Interested in publishing with InTechOpen?
Contact us at book.department@intechopen.com

Generalized Regression Neural Networks with Application in Neutron Spectrometry

Ma. del Rosario Martínez-Blanco,
Víctor Hugo Castañeda-Miranda,
Gerardo Ornelas-Vargas,
Héctor Alonso Guerrero-Osuna,
Luis Octavio Solis-Sanchez,
Rodrigo Castañeda-Miranda,
José María Celaya-Padilla, Carlos Eric Galvan-Tejada,
Jorge Isaac Galvan-Tejada,
Héctor René Vega-Carrillo,
Margarita Martínez-Fierro, Idalia Garza-Veloz and
Jose Manuel Ortiz-Rodriguez

Additional information is available at the end of the chapter

<http://dx.doi.org/10.5772/64047>

Abstract

The aim of this research was to apply a generalized regression neural network (GRNN) to predict neutron spectrum using the rates count coming from a Bonner spheres system as the only piece of information. In the training and testing stages, a data set of 251 different types of neutron spectra, taken from the International Atomic Energy Agency compilation, were used. Fifty-one predicted spectra were analyzed at testing stage. Training and testing of GRNN were carried out in the MATLAB environment by means of a scientific and technological tool designed based on GRNN technology, which is capable of solving the neutron spectrometry problem with high performance and generalization capability. This computational tool automates the pre-processing of information, the training and testing stages, the statistical analysis, and the post-processing of the information. In this work, the performance of feed-forward backpropagation neural networks (FFBPNN) and GRNN was compared in the solution of the neutron spectrometry problem. From the results obtained, it can be observed that

despite very similar results, GRNN performs better than FFBPNN because the former could be used as an alternative procedure in neutron spectrum unfolding methodologies with high performance and accuracy.

Keywords: artificial intelligence, statistical artificial neural networks, neutron spectrometry, unfolding codes, spectra unfolding

1. Introduction

Artificial Intelligence or AI is one of the newest fields of intellectual research that attempts to understand the intelligent entities [1]. Intelligence could be defined by the properties it exhibits: an ability to deal with new situations, to solve problems, to answer questions, to devise plans, and so on [2]. The phrase AI was coined by John McCarthy in the 1940s and to date evades a concise and formal definition [3]. A simple definition might be: AI is the study of systems that act in a way, that to any observer would appear to be intelligent, and involves using methods based on the intelligent behavior of humans and other animals to solve complex problems.

AI has been classified into three periods: the classical, the romantic, and the modern periods [1–4]. The major area of research covered under the classical period, in the 1950s, was intelligent search problems involved in game-playing and theorem proving. In the romantic period, from the mid-1960s until the mid-1970s, people were interested in making machines “understand,” by which they usually meant the understanding of natural languages. The modern period started from the latter half of 1970s to the present day and includes research on both, theories and practical aspects of AI. This period is devoted to solving relatively simple or complex problems that are integral to more complex systems of practical interest.

The aim of the study of AI is to use algorithms, heuristics, and methodologies based on the ways in which the human brain solves problems. In the most recent decades, AI areas of particular importance include multi-agent systems; artificial life; computer vision; planning; playing games, chess in particular; and machine learning [5–6].

1.1. Machine learning and connectionism

Learning and intelligence are intimately related to each other. Learning is an inherent characteristic of human beings [3]. By virtue of this, people, while executing similar tasks, acquire the ability to improve their performance with the self-improvement of future behavior based on past experience. In most learning problems, the task is to learn to classify inputs according to a finite, or sometimes infinite, set of classifications [2]. Typically, a learning system is provided with a set of training data, which have been classified by hand. The system then attempts to learn from these training data how to classify the same data, usually a relative easy task, and also how to classify new data that are not seen [7].

The principles of learning can be applied to machines to improve their performance [8]. A system capable of learning is intelligent and is usually expected to be able to learn based on

past experience. Such learning is usually referred to as “machine learning” (ML) which is an important part of AI and can be broadly classified into three categories: supervised, unsupervised, and reinforcement learning.

Supervised learning requires a trainer who supplies the input-output training instances. The learning system adapts its parameters using some algorithms to generate the desired output patterns from a given input pattern. In absence of trainers, the desired output of a given input instance is not known; consequently, the learner has to adapt its parameters autonomously. Such type of learning is termed unsupervised learning.

Reinforcement learning bridges the gap between the supervised and unsupervised categories. In reinforcement learning, the learner does not explicitly know the input-output instances, but it receives some form of feedback from its environment. The feedback signals help the learner to decide whether its action on the environment is rewarding or punishable. The learner thus adapts its parameters based on the states (rewarding/punishable) of its actions.

Recently, the connectionist approach for building intelligent machines with structured models like artificial neural networks (ANN) is receiving more attention [9]. Connectionist models are based on how computation occurs in biological neural networks. Connections play an essential role in connectionist models, hence the name *connectionism* [10]. The term connectionism was introduced by Donald Hebb in the 1940s, and it is a set of approaches in the fields of AI that models mental or behavioral phenomena as the emergent processes of interconnected networks of simple units [11]. The central connectionist principle is that mental phenomena can be described by interconnected networks of simple and uniform units.



Figure 1. The unit: the basic information processing structure of a connectionist model.

Units are to a connectionist model what neurons are to a biological neural network: the basic information processing structures. Since the flow of information in a network occurs through its connections, the link through which information flows from one member of the network to the next is known as synapses. Synapses are to neural networks what an Ethernet cable or telephone wire is to a computer network. Without synapses from other neurons, it would be impossible for a neuron to receive input and to send output from and to other neurons, respectively. Given the crucial role that connections play in a network of neurons, synapses in a biological neural network matter as much as the neurons themselves [12].

Most connectionist models are computer simulations executed on digital computers. In a connectionist computer model, units are usually represented by circles as shown in **Figure 1**. Because no unit by itself constitutes a network, connectionist models typically are composed of many units as illustrated in **Figure 2**. However, neural networks are organized in layers of neurons. For this reason, connectionist models are organized in layers of units as shown in **Figure 3**. **Figure 3** is still not a network because no group of objects qualifies as a network

unless each member is connected to other members; it is the existence of connections that make a network, as illustrated in **Figure 4** [13].




Figure 2. Connectionist model with 11 units.

Figure 3. Connectionist model organized in layers.




Figure 4. Network connectionist model.

In **Figure 4**, it can be seen that network connections are conduits through which information flows between the members of a network. In the absence of such connections, no group of

objects qualifies as a network. There are two kinds of network connections: input and output. An input connection is a conduit through which a member of a network receives information. An output connection is a conduit through which a member of a network sends information. Although it is possible for a network connection to be both an input connection and an output connection, a unit does not qualify as a member of a network if it can neither receive information from other units nor send information to other units.

There are many forms of connectionism, but the most common forms use neural network models [14]. The form of the connections and the units can vary from model to model as shown in **Figures 5–9**, where it can be seen that any number of units may exist within each layer, and each unit of each layer is typically linked via a weighted connection to each node of the next layer. Data are supplied to the network through the input layer.




Figure 5. Single-layered recurrent net with lateral feedback structure.

Depending on the nature of the problems, neural network models are organized in different structural arrangements (architectures or topologies) [10]. The neural network architecture defines its structure including the number of hidden layers, number of hidden nodes, and number of nodes at the input and output layers. There are several types of ANN architectures. As illustrated in **Figures 5–9**, most of the widely used neural network models can be divided into two main categories: feed forward neural networks (FFNN) and feedback neural networks (FBNN) [10–14].




Figure 6. Two-layered feed-forward structure.

As shown in **Figures 6 and 8**, FFNNs allow signals to travel one way only; data enters the inputs and passes through the network, layer by layer, until it arrives at the output. There is no feedback or loops between layers. These networks are extensively used in pattern recognition and classification. FBNN can have signals traveling in both directions by introducing loops in the network as shown in **Figures 5, 7, and 9**. FBNNs are dynamic; their state changes continuously until they reach an equilibrium point. They remain at the equilibrium point until the input changes and a new equilibrium needs to be found.




Figure 7. Two-layered feedback structure.




Figure 8. Three-layered feed-forward structure.




Figure 9. Single-layered recurrent structure.

In most connectionist models, units are organized into three layers: an input layer, one or more “hidden” layers, and an output layer [10–14]. **Figures 4** and **8** show a 3-layered FFNN consisting of 3 layers of units, where each unit is connected to each unit above it, and where information flows “forward” from the network’s input units, through its “hidden” units, to its output units. The nodes of the hidden layer process input data they receive as the sum of the weighted outputs of the input layer. Nodes of the output layer process input data they receive as the sum of the weighted output of the units within the hidden layers, and supply the system output.




Figure 10. Supervised learning of ANN.

As mentioned earlier, the principles of learning can be applied to machines to improve their performance [15]. In FFNN, network learning is a very important process. The learning situation can be divided into two major categories: supervised and unsupervised. With supervised learning, the ANN must be trained before it becomes useful. Training consists of

presenting input and output data to the network. **Figure 10** shows the distinguishing nature of supervised neural network, which incorporates an external trainer in which input and output are known, and its objective is to discover a relationship between the two. In this mode, the actual output of ANN is compared to the desired output.

An important issue concerning supervised learning is the problem of error convergence: the minimization of error between the desired and computed values. The performance of the network is evaluated based on the comparison between the computed (predicted) output and actual (desired) output value [10–15]. There are several types of measurements of prediction accuracy; the most common measurements used are as follows:

1. Coefficient of determination (R^2)

$$R^2 = \frac{\sum_{i=1}^n (\hat{Y}_i - \bar{Y})^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2} \quad (1)$$

2. Mean Square Error (MSE)

$$MSE = \frac{1}{n} \sum_{i=0}^n (Y_i - \hat{Y}_i)^2 \quad (2)$$

3. Root Mean Square Error (RMSE)

$$RMSE = \left[\frac{1}{n} \sum_{i=0}^n (Y_i - \hat{Y}_i)^2 \right]^{1/2} \quad (3)$$

4. Mean Absolute Percentage Error (MAPE)

$$MAPE\% = \frac{1}{n} \sum_{i=0}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \times 100 \quad (4)$$

where Y_i is the actual value of output, \hat{Y}_i is the predicted value, and (n) is the number of observations.

Unlike supervised learning, unsupervised neural network uses no external feedback and it is based upon only local information. As can be seen from **Figure 11**, in unsupervised learning only the input is known and the goal is to uncover patterns in the features of the input data. It is also referred to as self-organization, in the sense that it self-organizes data presented to the network and detects their emergent collective properties. Unsupervised learning's goal is to have the computer learn how to do something that we do not tell it how to do. The common applications of unsupervised learning are classification, data mining, and self-organizing maps (SOM), also called Kohonen Neural Network (KNN).




Figure 11. Unsupervised learning of ANN.

In FFNN with supervised training, two very different types of neural networks exist: FFNN trained with Backpropagation (BP) algorithm (FFBPNN) and Statistical Neural Networks (SNN) [10, 11, 14]. FFBPNNs use equations that are connected using weighting factors [11]. The selection of the weighting factors makes these neural nets very powerful. The multilayer perceptron (MLP) is the most common and successful neural network architecture with FFNN topologies, while the most common supervised learning technique used for training artificial neural networks is the multilayer backpropagation (BP) algorithm [10–15].

BP is a systematic method for training multilayer FFNN as shown in **Figure 8**. Since it is a supervised training algorithm, both the input and the target patterns are given (**Figure 10**). For a given input pattern, the output vector is estimated through a forward pass on the network. After the forward pass is over, the error vector at the output layer is estimated by taking the component-wise difference of the target pattern and the generated output vector. A function of errors of the output layered nodes is then propagated back through the network to each layer for adjustment of weights in that layer. The weight adaptation policy in BP algorithm is derived following the principle of steepest descent approach of finding minima of a multi-valued function.

BPFNNs consist of neurons organized into one input layer and one output layer and several hidden layers of neurons as shown in **Figure 8**. Neurons perform some kind of calculation using inputs to compute an output that represents the system. The outputs are given on to the next neuron. An edge indicates to which neurons the output is given. These arcs carry weights.

Generally, BP learning consists of two passes: a forward pass and a backward pass. In the forward pass, an activity pattern is applied to the sensory nodes of the network. It is at last

that a set of outputs is produced as the actual responses of the network. During this path, the synaptic weights are fixed. During backward pass, the synaptic weights are adjusted in accordance with an error correction rule.

BPFNNs have the desirable characteristic of being very flexible. They can be used for pattern recognition as well as for decision-making problems. Another advantage is that like for every other neural network, the process is highly parallel and therefore the use of parallel processors is possible and cuts down the necessary time for calculations. However, BPNNs have negative characteristics. The training of the network can need a substantial amount of time [16]. The size of the training data for BPFNN has to be very large. In some instances, it is almost impossible to provide enough training.

On the other hand, SNNs use statistical methods to select the equations within the structure and do not weigh these functions differently [17].

1.2. Statistical neural networks

SNNs are an important and very popular type of neural networks that mainly depend on statistical methods and probability theory [18]. Three of the most important types of these networks are Radial Basis Function Neural Network (RBFNNs), Probabilistic Neural Network (PNNs), and General Regression Neural Network (GRNNs) [19].

1.2.1. Radial basis function neural network

RBFNN was introduced by Broomhead and Lowe in 1988 and is a popular alternative to FFBPNN [20]. The behavior of the network depends on the weights and the activation of a transfer function F , specified for the units [21]. Activation functions are mathematical formulas that determine the output of a processing node [22]. The activation function maps the sum of weighted values passed to them by applying F into the output value, which is then “fired” on to the next layer.

There are several kinds of transfer or activation functions, typically falling into four common categories: Linear function (LF), Threshold function (TF), Sigmoid Function (SF), and Radial Basis Function (RBF) [23]. RBFs are a special class of activation functions which form a set of basis functions, one for each data set. The general form of RBF is:

$$G(\|X - \mu\|) \tag{5}$$

where $G(\cdot)$ is a positive nonlinear symmetric radial function (kernel); X is the input pattern and μ is the center of the function. Another important property of RBF is that its output is symmetric around the associated center μ . Thus, $f(X_i)$ can be taken to be a linear combination of the outputs of all the basis functions:

$$f(x) = \sum_{i=1}^n w_i G(x - \mu) \tag{6}$$

There are several common types of radial basis functions represented in **Table 1** [19–23]:

Function name	Mathematical form
Thin plate spline	$G(x) = (x - \mu)^2 \log(x - \mu)$
Multi-quadratic	$G(x) = \sqrt{(x - \mu)^2 + \sigma^2}$
Inverse multi-quadratic	$G(x) = \frac{1}{\sqrt{(x - \mu)^2 + \sigma^2}}$
Gaussian	$G(x) = \exp\left(-\frac{(x - \mu)^2}{\sigma^2}\right)$

Table 1. Types of radial basis functions.

where these function parameters are the center (μ) and the radius (σ^2). A Gaussian function, also called “bell shaped curve” or normal distribution, is the most common applicable type of RBF. It is suitable not only in generalizing a global mapping but also in refining local features. The Gaussian function tends to be local in its response and is biologically more acceptable than other functions. RBF is unique, because unlike the others, it monotonically decreases with distance from the center, and forms the classic bell shaped curve which maps high values into low ones, and maps mid-range values into high ones. A plot of a Gaussian function is represented in **Figure 12**.




Figure 12. Plot representing a Gaussian function.

The mathematical form of this function for the case of a single variable is given by:

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (7)$$

where

$$\mu = E(X) = \int_{-\infty}^{\infty} x \cdot f(x) dx \quad (8)$$

$$\sigma^2 = E(X - \mu)^2 = \int_{-\infty}^{\infty} (x - \mu)^2 \cdot f(x) dx \quad (9)$$

μ : is the mean (center) of the distribution.

σ^2 : is the variance (width or radius) of distribution.

Extending the formula (7) to multiple dimensions, we can get the general Gaussian probability density:

$$f(x) = \frac{1}{(2\pi)^{p/2} |\Sigma|^{p/2}} \exp\left(-\frac{1}{2}(\underline{x} - \underline{\mu})^T \Sigma^{-1} (\underline{x} - \underline{\mu})\right) \quad (10)$$

where p is the number of dimensions, μ is the mean p -dimensional vector and Σ is the covariance $p \times p$ matrix.

RBFNNs are useful in solving problems where the input data are corrupted with additive noise and can be used for approximating functions and recognizing patterns [24]. As shown in **Figure 13**, the RBFNN has a feed forward architecture, and it is composed of many interconnected processing units or neurons organized in three successive layers. The first layer is the input layer. There is one neuron in the input layer for each predictor variable. The second layer is the hidden layer. This layer has a variable number of neurons. Each neuron consists of a RBF centered on a point with as many dimensions as there are predictor variables.

The standard euclidean distance is used to measure how far an input vector is located from the center. The value coming out from the neuron in the hidden layer is multiplied by a weight (W_i) associated with the neuron, also a bias value that is multiplied by a weight (W_o), is passed to the summation layer which adds up the weighted values and presents this sum as the network outputs.

The training of RBFNNs is radically different from the training of FFNNs [19–24]. RBFNN training may be done in two stages: First, calculating the RBF parameters, including centers

and the scaling parameter. Various parameters, such as the number of neurons in the hidden layer, the coordinates of the center of each hidden layer function, the radius (width) of each function in each hidden unit, and the weights between the hidden and output units, are determined by the training process; second, estimating the weights between the hidden and output layers. Opposed to BPFNN, in RBFNN training, there is no changing of the weights with the use of the gradient method for function minimization. In RBFNNs, training resolves itself into selecting the centers and calculating the weights of the output neuron.

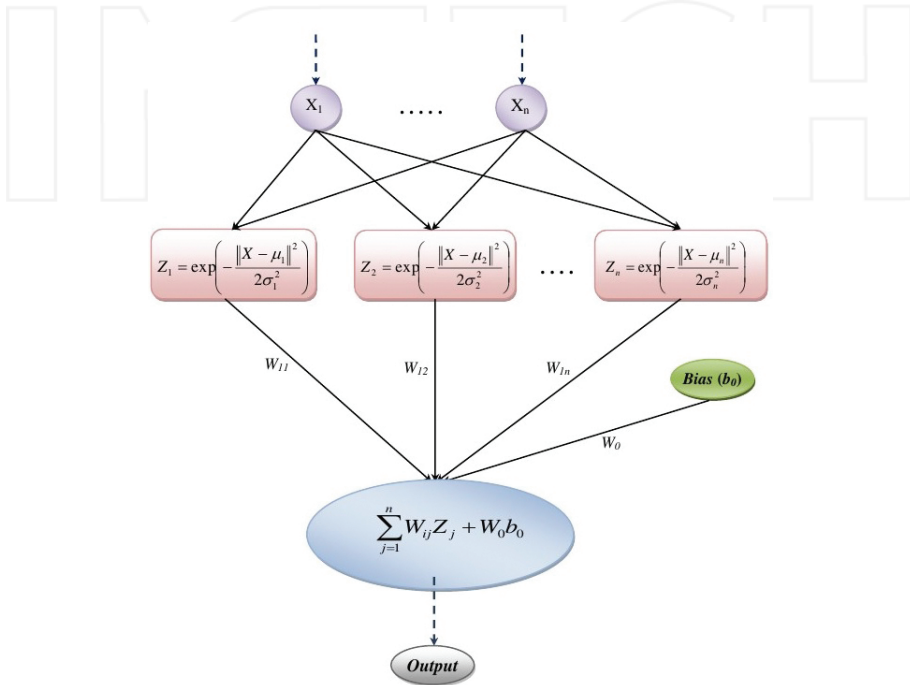


Figure 13. Network architecture of RBFNN.

The center (μ) and width radius (σ) of the radial function and final weights are the parameters of the model. Many algorithms have been designed to determine these parameters by minimizing the error between the target and actual output. Determination of centers is important for the success of the RBFNN and there are several methods to choose suitable centers for network, such as random selection from data set, randomly fixed, and clustering approach.

Determination of the width is very important for the success of the RBFNN. If the width values are large, the model will not be able to closely fit the function; on the other hand, a large width parameter would give better generalization but poorer output. A small width parameter gives good recall of the training patterns but poor generalization, and the model will over fit the data because each training point will have too much influence. There are several methods to

determine the width. Two of the common methods for width selection are fixed method and distance averaging.

The number of hidden units is very important and plays a major role in RBFNN performance. It is very difficult to find a suitable number of hidden units. If the number of hidden units is too low, the network cannot reach a desired level of performance because of an insufficient number of hidden neurons. Many researchers assumed that the number of hidden units is fixed and is chose a priori.

There are several types of learning that can be used in RBFNNs, such as General Regression Neural Network (GRNN), Orthogonal Least Squares, K-Means Clustering, and P-Nearest Neighbour.

1.2.2. Probabilistic neural network

Specht first introduced the probabilistic neural network (PNN) in the 1990s. It closely related to “the Bayes Strategy for Pattern Classification” rule and Parzen nonparametric probability density function estimation theory. It performs classification where the target variable is categorical [19–24].




Figure 14. Block diagram of a probabilistic neural network (PNN).

PNNs are often more accurate than FFNNs and it is usually much faster to train PNNs than FFNNs. The greatest advantages of PNNs are the fact that the output is probabilistic which makes interpretation of output easy, and the training speed. Training a PNN is very fast because it requires that each pattern be presented to the network only once during training, unlike BPFNNs, which require feedback of errors and adjusting weights and many presentations of training patterns. These PNNs, with variation can be used for mapping, classification, and associative memory. The greatest disadvantage is the network size since PNNs require more memory space to store the model.

The general structure of PNN, which is presented in **Figure 14**, consists of four layers. The first layer is the input layer. The input unit nodes do not perform any computation and simply distribute the input to the neurons in the first hidden layer (pattern layer). There is one neuron in the input layer for each predictor variable.

The second layer is the pattern layer. Each pattern unit represents information on one training sample. Each pattern unit calculates the probability of how well the input vector fits into the pattern unit. The neurons of the pattern layer are divided into K groups, one for each category. The i -th pattern neuron in the k -th group computes its output using a Gaussian kernel with the form:

$$f_{A_i}(X) = \frac{1}{(2\pi\sigma^2)^{p/2}} \exp \left[-\frac{(X - X_{A_i})^T - (X - X_{A_i})}{2\sigma^2} \right] \quad (11)$$

where:

i : is the pattern number.

p : denotes the dimension of the pattern vector x .

σ : is the smoothing parameter of the Gaussian Kernel.

X_{A_i} : is the center of the kernel.

The third layer is the summation layer. In the summation layer, there is one pattern neuron for each category of the target variable. The neurons of this layer compute the approximation of the conditional class probability function through a combination of the previously computed densities as the following equation:

$$f_A(X) = \frac{1}{(2\pi\sigma^2)^{p/2}} \frac{1}{M} \sum_{i=1}^M \exp \left[-\frac{(X - X_{A_i})^T - (X - X_{A_i})}{2\sigma^2} \right] \quad (12)$$

The fourth layer is the output layer (also called decision layer). At the output layer, we have a hard-limiting threshold: (+1) whenever an input pattern X belongs to category (A), and (-1) if it is from category (B).

The use of PNN is especially advantageous due to its ability to converge to the underlying function of the data with only few training samples available. The additional knowledge needed to get the fit in a satisfying way is relatively small and can be done without additional input by the user. GRNN falls into the category of PNN. This neural network, like other SNNs, needs only a fraction of the training samples a BPFNN would need, mainly because the data available from measurements of an instance is generally never enough for a BPFNN. This makes GRNN a very useful tool to perform predictions and comparisons of system performance in practice.

The invention of GRNN was a great turn in the history of neural networks. Researchers from many fields including medicine, engineering, commerce, physics, chemistry, geology, statistics, etc., benefited from this technique for their research.

1.2.3. Generalized regression neural network

GRNN is a type of supervised FFNN and is one of the most popular neural networks. Donald F. Specht first introduced it in 1991. Specht's GRNN is related to his probabilistic neural network (PNN) classifier. Like PNN networks, GRNNs are known for their ability to train quickly on sparse data sets. Rather than categorizing data like PNN, GRNN applications are able to produce continuous valued outputs. An important by-product of the GRNN network is Bayesian posterior probabilities. The training of GRNN networks is very fast because the data only needs to propagate forward once, unlike most other BPNNs, where data may be propagated forward and backward many times until an acceptable error is found [19–24].

GRNNs work well on interpolation problems. However, because they are function approximators, they tend to trade accuracy for speed. The GRNN is used for estimation of continuous variables, as in standard regression techniques. It uses a single common radial basis function kernel bandwidth (σ) that is tuned to achieve optimal learning.

The regression performed by GRNN is in fact the conditional expectation of Y , given $X = x$. In other words, it outputs the most probable scalar Y given specified input vector x . Let $f(x, y)$ be the joint continuous probability density function of a vector random variable, X , and a scalar random variable, Y . Let x be a particular measured value of the random X . The regression of Y given x (also called conditional mean of Y given x) is given by:

$$E[Y / x] = \int_{-\infty}^{\infty} Y \cdot f(Y / x) dy = \frac{\int_{-\infty}^{\infty} Y \cdot f(x, Y) dy}{\int_{-\infty}^{\infty} f(x, Y) dy} \quad (13)$$

If the relationship between independent (X) and dependent (Y) variables is expressed in a functional form with parameters, then the regression will be parametric. Without any real

knowledge of the functional form between the x and y , nonparametric estimation method will be used. For a nonparametric estimate of $f(x, y)$, we will use one of the consistent estimators that is a Gaussian function. This estimator is a good choice for estimating the probability density function, f , if it can be assumed that the underlying density is continuous and that the first partial derivatives of the function evaluated at any x are small. The good choice for probability estimator $\hat{f}(x, y)$ is based on sample values x_i and y_i of the random variables X and Y is given by:

$$\hat{f}(x, y) = \frac{1}{(2\pi)^{\frac{(p+1)}{2}\sigma^{p+1}}} \cdot \frac{1}{n} \sum_{i=1}^n \left\{ \exp \left[-\frac{(X - X_i)^T (X - X_i)}{2\sigma^2} \right] \exp \left[-\frac{(Y - Y_i)^2}{2\sigma^2} \right] \right\} \quad (14)$$

p : is the dimension of the vector variable.

n : is the number of training pairs ($x_i \rightarrow y_i$).

σ : is the single learning or smoothing parameter chosen during network training.

Y_i : is desired scalar output given the observed input x_i .

The topology of GRNN presented in **Figure 15** consists of four layers: The first layer is the input layer that is fully connected to the second layer. The input units are merely distribution units, which provide all of the (scaled) measurement variables X to all of the neurons on the second layer, the pattern units. The second layer is the first hidden layer (also called the pattern layer). This layer consists of N processing elements or nodes, where N is the number of sample within a training data set and each node represents the input vector, X_i , associated with the vector assigned with the j th sample in training data. In each node, each input vector is subtracted from the vector assigned to the node, X_j . This difference is then squared by the node. The result is fed into a nonlinear kernel, which is usually an exponential function. The pattern unit outputs are passed on to the summation units.

Note that the second hidden layer always has exactly one more node than the output layer. When you need a multidimensional (vector) output, the only change to the network is to add one additional node to the second hidden layer, plus an additional node in the output layer for each element of the output vector.

The third layer is the second hidden layer (Summation layer) which has two nodes. The input to the first node is the sum of the first hidden layer outputs, each weighted by the observed output y_j corresponding to X_j . The input of the second node is the summation of the first hidden layer activations.

The fourth layer is the output layer. It receives the two outputs from the hidden layer and divides them to yield an estimate for y (or to provide the prediction result).

In the GRNN architecture, unlike other network architectures as in BP, there are no training parameters such as learning rate and momentum, but there is a smoothing factor (σ) that is

applied after the network is trained. The choice of smoothing factor (parameter) of the kernel σ is very important. It has the effect of smoothing the training examples. Small values of σ tend to make each training point distinct, whereas large values force a greater degree of interpolation between the training observations. For GRNNs, the smoothing factor must be greater than 0 and can usually range from 0.01 to 1 with good results. We need to experiment in order to determine which smoothing factor is most appropriate for our data.




Figure 15. The basic GRNN architecture.

A useful method of selecting an appropriate σ is the Holdout method. For a particular value of σ , the Holdout method consists in removing one sample at a time and constructing a network based on all of the other samples. The network is then used to estimate Y for the removed sample. By repeating this process for each sample and storing each estimate, the mean square error can be measured between the actual sample values Y_i and the estimates. The value of σ giving the smallest error should be used in the final network.

Fortunately, in most applications there is a unique σ which produces the minimum MSE between the network output and the desired output for the testing set that can be found quickly by trial and error.

2. Neutron spectrometry by means of generalized regression neural networks

2.1. Neutron spectrometry

In general, neutrons are more difficult to detect than gamma rays because of their weak interaction with matter and their large dynamic range in energy [25]. Neutrons have mass but no electrical charge [26]. Because of this, they cannot directly produce ionization in a detector, and therefore cannot be directly detected. This means that neutron detectors must rely upon a conversion process where an incident neutron interacts with a nucleus to produce a secondary charged particle [27]. These charged particles are then directly detected and from them the presence of neutrons is deduced.

The derivation of the spectral information is not simple because the unknown is not given directly as a result of measurements [28]. The spectral information is derived through the discrete version of the Fredholm integral-differential equation of first type [29]. Normally, researchers solve a discrete version of this equation, which gives an ill-conditioned system of equations which have no explicit solution, may have no unique solution, and are referred to as ill-posed [30].

Since the 1960s, the Bonner Sphere Spectrometer (BSS) has been the most used method for radiological protection purposes [28]. The isotropy of the response, the wide energy range (from thermal to GeV neutrons), and the easy operation make these systems still applicable. BSS consists of a thermal neutron detector located at the center of several high-density polyethylene spheres of different diameters [29]. By measuring the count rates with each sphere individually, an unfolding process can, in principle, provide some information about the energy distribution of the incident neutrons.

The most delicate part of neutron spectrometry based on BSS is the unfolding process [30]. The unfolding spectrum of the neutrons measured consists of establishing the rate of energy distribution of fluency, known as response matrix, and the group of carried-out measures. Because the number of unknowns overcomes the number of equations, this ill-conditioned system has an infinite number of solutions. The process of selecting the solution that has meaning for the problem is part of the unfolding process.

To solve the system of equations for BSS unfolding, several approaches have been used [29]: iterative procedures, Monte Carlo, regularization, and maximum entropy methods. The drawbacks associated with these traditional unfolding procedures have motivated the need for complementary approaches. Novel methods based on AI have been suggested. In neutron spectrometry, the theory of ANN has offered a promising alternative to the classic calculations

with traditional methods. Previous researches indicate that BPFNNs perform well and have been the most popular networks used in neutron spectrometry [30–35].

BPFNN have the characteristic of being very flexible; the process is highly parallel and can be used to solve diverse problems; however, this neural network topology has some drawbacks: the structural and learning parameters of the network are often determined using the trial-and-error technique [36]. This produces networks with poor performance and generalization capabilities which affect its application in real problems. Training can require a substantial amount of time to gradually approach good values of the weights. The size of the training data has to be very large and often it is almost impossible to provide enough training samples as in the case of the neutron spectrometry problem.

Another drawback is that adding new information requires retraining the network and this is computationally very expensive for BPFNN, but not for GRNN which belongs to SNNs. GRNNs use a statistical approach in their prediction algorithm given the bases in the Bayes strategy for pattern recognition. To be able to use the Bayes strategy, it is necessary to estimate the probability density function accurately. The only available information to estimate the density functions is the training samples. These strategies can be applied to problems containing any number of categories as in the case of the neutron spectrometry problem.

2.2. Neutron spectrometry by means of generalized regression neural networks

A GRNN has certain differences compared to BPFNN approach [24]. The learning of BPFNN can be described as trial and error. This is no longer the case of the GRNNs because they use a statistical approach in their prediction algorithm which is capable of working with only few training samples. The experience is learned not by trial but by experience others made for the neural network. GRNNs are very flexible and new information can be added immediately with almost no retraining. The biggest advantage is the fact that the probabilistic approach of GRNN works with one-step-only learning.

A further big difference that exists between BPFNN and GRNN is the difference in the process inside the neurons. A GRNN uses functions that are based on knowledge resulting from the Bayes strategy for pattern classification. The structure of the calculations for the probabilistic density function in GRNN has striking similarities to a BPFNN. The strength of a GRNN lies in the function that is used inside the neuron.

It would be desirable to approach the parameters in one-step-only approach. The Bayes strategy for pattern classification extracts characteristics from the training samples to come to knowledge about underlying function.

In this work, both BPFNN and GRNN architectures were trained in order to solve the neutron spectrometry problem using customized technological tools designed with this purpose. A comparison of the performance obtained using both architectures was performed. Results obtained show that the two architectures solve the neutron spectrometry problem well, with high performance and generalization capabilities; however, the results obtained with GRNN are better than those obtained with BPFNN, mainly because GRNN does not produce negative values and oscillations around the target value.

As mentioned, a GRNN is a BPFNN based on non-linear regression. It is suited to function approximation tasks such as system modeling and prediction. While the neurons in the first three layers are fully connected, each output neuron is connected only to some processing units in the summation layer. The function of the pattern layers of the GRNN is a Radial Basis Function (RBF), typically the Gaussian kernel function.

In this work, a neutron spectrum unfolding computer tool based on neural nets technology was designed to train a GRNN capable of solving the neutron spectrum unfolding problem with high performance and generalization capabilities. The code automates the pre-processing, training, testing, validation, and post-processing stages of the information regarded with GRNN. The code is capable of training, testing, and validating GRNN. After training and testing the neural net, the code analyzes, graphs, and stores the results obtained.

2.3. Methods

The use of GRNN to unfold the neutron spectra from the count rates measured with the BSS is a promising alternative procedure; however, one of the main drawbacks is the lack of scientific and technological tools based on this technology. In consequence, a scientific computational tool was designed to train, to test, to analyze, and to validate GRNN in this research domain.

Statistical methods tend to put more emphasis on the structure of the data. For neural network methods, the structure of the data is secondary. Therefore, the amount of data needed for statistical methods is a lot smaller than the amount of data needed for ANN approaches. GRNNs are frequently used to classify patterns based on learning from examples. PNNs base the algorithm on the Bayes strategy for pattern recognition.

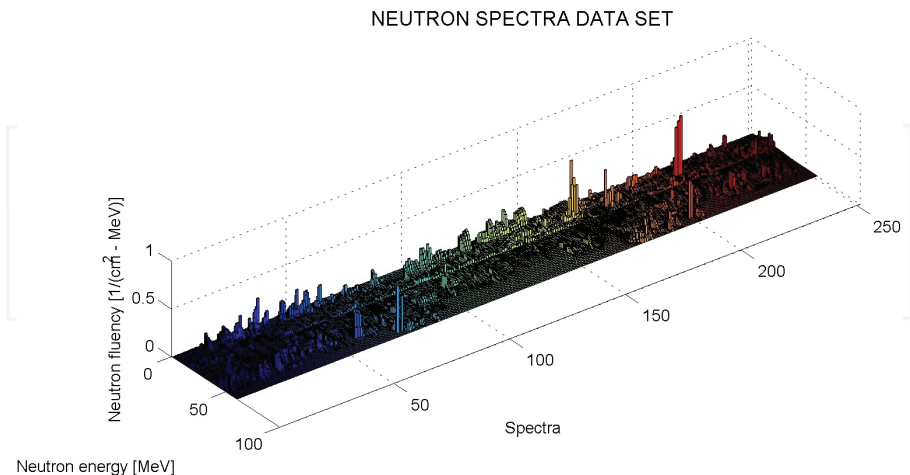


Figure 16. Neutron spectra data set expressed in energy units, used to train the GRNN.

In order to train both BPFNNs and GRNNs, the only available information is a neutron spectra compilation of the International Atomic Energy Agency (IAEA) which contains a collection of 251 different neutron spectra [37]. This compendium was made with the aim to provide specific technical information that could be used by radiation protection specialists for proper selection of dosimeters and survey instruments, and for interpretation of data obtained with these detectors.

The developed code based on GRNNs technology utilizes these 251 neutron spectra and both, the response matrixes from IAEA's compilation and those that could be introduced by the user. The designed technological tool automates the following activities:

- Read the neutron spectra data set coming from IAEA's compendium, which are expressed in 60 energy bins.
- Read a response matrix used to train the neural network.
- Because the neutron spectra coming from IAEA's compendium are expressed in lethargy units, the code converts these spectra in energy units.
- The neutrons expressed in energy units are multiplied by the selected response matrix in order to calculate the count rates.
- To train the GRNN, the code uses the 251 calculated count rates as entrance data, and their corresponding neutron spectra are expressed in energy units as the output data as shown in **Figure 16**.
- The code randomly generates the training data set, 80% of the whole data, and the testing data set, remaining 20%, as shown in **Figure 17**.
- Using the earlier calculated information, the following stage is to determine the spread constant value. To calculate this value, the computer tool trains several neural networks varying this value from 0 in increments of 0.01 through 2 and compares the mean square error (MSE), which is used to determine the performance of the network. The minimum value obtained is selected as the spread constant value (**Figure 18**).
- After the developed code selects the spread constant value, a final GRNN is trained.
- After training, a testing stage is performed in order to analyze the performance and generalization capabilities of the trained network. In this stage only the input is proportionated to the network. Fifty neutron spectra are randomly selected by the code to test the performance and generalization capabilities of the trained network. In order to analyze the performance of the trained network, chi square and correlation tests are performed.
- Finally, the code plots and stores the generated information.

In this work, a comparison of the performance obtained in the solution of the neutron spectrometry problem using two different neural network architectures, BPFNN and GRNN, is presented. Both BPFNN and GRNN were trained and tested using the same information: 251 neutron spectra, extracted from IAEA's compilation. Eighty percent of the whole data set,

randomly selected, was used at training stage and remaining 20% at testing stage. Fifty neutron spectra were used as testing data set.




Figure 17. Neutron spectra data set used at testing stage, compared with target spectra.




Figure 18. Optimum spread constant value, sigma, and determination.

The architectural and learning parameters of BPFNN were optimized using a statistical methodology known as Robust Design of Artificial Neural Networks Methodology (RDANNM) [36]. In GRNN, the only parameter determined was the spread constant value, known as sigma. For both architectures, BPFNN and GRNN, customized scientific computational tools were used for the training, testing, analysis, and storage of the information

generated in the whole process of both network architectures. It can be observed from the results obtained that although the two network architectures present very similar performance and generalization capabilities, GRNN performs better than BPFNN in the solution of the neutron spectrometry problem. BPFNNs produce negative values and high oscillations around the target values, which makes this type of network unusable in the solution of the problem mentioned.

2.4. Results

In this work, by using two different technological tools, two different artificial neural networks architectures, BPFNN and GRNN, were trained and tested using the same information. The performance of the networks was compared. From the results obtained, it can be observed that GRNN performs better than BPFNN in the solution of the neutron spectrometry problem.

Network parameters	BPNN (trial and error)	BPNN (RDANNM)	GRNN
Networks tested before training	Undetermined	50 in 150 minutes	2000 in 154 seconds
Hidden layers	Undetermined	1	Fixed architecture
Neurons in hidden layer	Undetermined	10	According input
Training algorithm	Undetermined	Trainscg	Statistical methods
Learning rate	Undetermined	0.1	–
Momentum	Undetermined	0.01	–
Spread constant	–	–	0.2711
Performance (MSE)	Undetermined	2.12E-4	2.48E-4
Training time (seconds)	Several hours	170.40	0.058
Epochs	Often millions	50E3	1
Best chi-square test BPNN	–	2.3525	0.049
Statistical margin 34.7			
Best correlation test BPNN	–	0.9928	0.99571
Statistical margin 1			
Worst chi-square test BPNN	–	0.44704	0.3223
Worst correlation test BPNN	–	0.2926	0.46023

Table 2. Comparison between BPFNN and GRNN values in neutron spectrometry.

By using the RDANNM, around 50 different network architectures were trained in 150 minutes average, before the selection of the near-optimum architecture. By testing different network architectures according to RDANNM, each network was trained in 50E3 epochs and 180 seconds average, stopping the training when the network reached the established mean square error (MSE) equal to 1E-4, the value used to measure the network performance. After selecting

the near-optimum architectural and learning parameters of the BPFNN, the network was trained and tested using the values shown in **Table 2**: one hidden layer with 10 neurons, a trainscg training algorithm, and a learning rate and momentum equal to 0.1 and 0.01, respectively.

As can be seen in **Table 2**, contrary to BPFNN the spread constant or sigma was the only value determined in GRNN. Using the same training and testing data sets used for BPFNN, around 2000 neural networks were trained in 154 seconds average in order to determine the spread constant equal to 0.2711. Each GRNN was trained in 0.058 seconds average in only one-step-only learning. Further, a final GRNN was trained and tested in 0.058 seconds average in only one epoch.

Table 2 shows the values obtained after training the two network architectures compared in this work. As can be seen, when the trial-and-error technique is used, it is very difficult to determine if the performance of the network is good or bad, mainly because a scientific and systematic methodology is not used for determining the near-optimum learning and architectural values as when RDANM is used.

As can be appreciated in **Table 2**, after training both network architectures, BPFNN was optimized using RDANM and GRNN, the performance, MSE, reached by the two networks is very close to each other. In BPFNNs, the MSE is a value optimized by the network designer using RDANM; in GRNN network the value was automatically obtained by the network based on the training information used by the automated code. The anterior demonstrates the powerful RDANM in the optimization of the near-optimum values of BPFNN architectures.

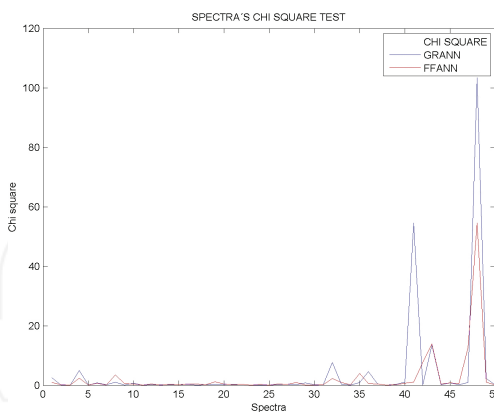


Figure 19. Chi-square test comparison for BPFNN and GRNN.

Figures 19 and 20 show that at testing stage, the chi square and correlation tests are very close in both BPFNN and GRNN network architectures. The same 50 neutron spectra were used for testing the two network architectures. At testing stage, only the count rates were proportionated to the trained networks. The output produced by the networks was compared with

the expected neutron spectrum taken from IAEA’s compilation by means of chi square and correlation tests. In the trained networks, two spectra are above the statistical margin of the chi-square test. In correlation tests, two values are below 0.5. This shows the high performance of the networks.




Figure 20. Correlation test comparison for BPFNN and GRNN.

As can be seen from **Figures 19** and **20**, the 50 chi-square and correlation tests of trained networks are very similar. In both cases, the average value is around 0 and 0.8 respectively, which is near the optimum values equal to 0 and 1. This means that BPFNN and GRNN have high performance and generalization capabilities and demonstrates the effectiveness of the RDANNM in the design of near-optimum architectures of BPFNN.




Figure 21. Best spectrum obtained with BPFNN.

As mentioned earlier, 50 neutron spectra were randomly selected at the testing stage. The same training and testing data sets were used to train and to test the performance and generalization capability of the networks. The best and the worst cases for both BPFNN and GRNN are showed in **Figures 21–28**. **Figures 21–22** and **23–24** show the best cases observed at testing stage for BPFNN and GRNN, respectively. From these figures, it can be observed that the chi-square and correlations tests for both BPFNN and GRNN are near 0 and 1, respectively, which means that the compared neutron spectra are very similar.




Figure 22. Best chi-square and correlation tests for spectrum obtained with BPN.




Figure 23. Best spectrum obtained with GRFFNN.




Figure 24. Best chi-square and correlation tests for spectrum obtained with GRNN.

As can be appreciated in **Figures 21–28**, despite the good results obtained with BPFNN, one drawback is that the calculated neutron spectra produce negative values which have no meaning in real problems. These negative values are eliminated from the output produced by the network; however, when the BPFNN is applied in real workplaces, because the training received, the network tends to produce negative values and oscillations around the target value. GRNN networks do not produce these negative values and oscillations and therefore the performance is better than BPFNN in the solution of the neutron spectrometry problem.




Figure 25. Worst spectrum obtained with BPFNN.

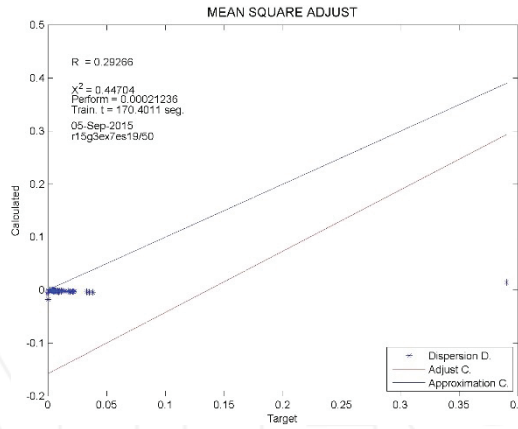


Figure 26. Worst chi-square and correlation tests for spectrum obtained with BPNN.

Figures 25–28 show the worst case observed at the testing stage for BPFNN and GRNN networks, respectively. As can be seen from these figures, both BPFNN and GRNN selected the same neutron spectra as the worst. This could be because of the 50 energy bins that the neural networks calculated; 49 values are very similar and only one value is far from the expected target value, which causes that the chi-square and correlation tests to produce low values. From Figures 25–28, it can be observed that in the GRNN architecture, the output is closer to the target values of the neutron spectra if compared with BPFNN. This shows that in the worst case, GRNNs have better performance than BPFNN.




Figure 27. Worst spectrum obtained with BPFNN.




Figure 28. Worst chi-square and correlation tests for spectrum obtained with GRNN.

The results observed in this work indicate that GRNN is able to predict the unknown neutron spectrum presented to the network with good accuracy. As can be seen from **Figures 21–24**, due to proper selection of the spread constant value, the GRNN calculated values, each one of the 60 energy bins of the spectrum, are around the target value (the spectrum from IAEA's compendium). As opposed to BPFNN, non-negative values and oscillations around the target value are generated when GRNNs are used.

Since there is only one parameter in GRNN, this type of ANN is also called a nonparametric model. It stores the training data as the parameter, rather than calculating and modifying the weights and bias in each hidden layer as the input data imported into the model. When the query comes, the model will calculate the value by summing the values of the other points weighted by the RBF function. Therefore, unlike parametric models such as BP, there are no weights and bias information produced to characterize the trained model.

3. Discussion and conclusions

Different approaches exist to model a system with available data. Each one of them has its own qualities and therefore advantages. GRNN falls into the category of PNN. This neural network, like other PNNs, needs only a fraction of the training samples a BPNN would need. The data available from measurements of an instance is generally never enough for a BPNN. Therefore, the use of GRNN is especially advantageous due to its ability to converge to the underlying function of the data with only few training samples available. The additional knowledge needed to get the fit in a satisfying way is relatively small and can be done without additional input by the user.

Statistical methods tend to put more emphasis on the structure of the data. For neural network methods, the structure of the data is secondary. Therefore, the amount of data needed for statistical methods is a lot smaller than the amount of data needed for ANN approaches.

Most methods are asymptotically good but most of them have severe drawbacks as well. BPNNs need a very large number of training samples and need a lot of time to gradually approach good values of the weights. Addition of new information requires retraining and this is computationally very expensive for BPNN but not for PNN. PNNs have the big advantage that the prediction algorithm works with only few training samples. Other big advantage is that they are very flexible and new information can be added immediately with almost no retraining.

PNNs use a statistical approach in their prediction algorithm. The bases for the statistical approach are given in the Bayes strategy for pattern recognition. These strategies can be applied to problems containing any number of categories as in the case of the neutron spectrometry problem. To be able to use the Bayes strategy, it is necessary to estimate the probability density function accurately. The only available information to estimate the density functions is the training samples.

The structure of the calculations for the probabilistic density function has striking similarities to a backpropagation feed-forward neural network. PNNs are frequently used to classify patterns based on learning from examples. PNNs base the algorithm on the Bayes strategy for pattern classification. Different rules determine patterns statistics from the training samples. BPNN uses methods that are not based on statistical methods and need a long time and many iterations and feedback until it gradually approaches the underlying function. It would be desirable to approach the parameters in one-step-only approach. The Bayes strategy for pattern classification extracts characteristics from the training samples to come to knowledge about underlying function.

In this work, two different artificial neural networks architectures, BPNN and GRNN, were trained and tested using the same information. The performance of the networks was compared. From the results obtained, it can be observed that GRNN performs better than BPNN in the solution of the neutron spectrometry problem.

PNNs have a very simple structure and are therefore very stable procedures. PNNs perform very well for only few available training samples and the quality increases as the number of training samples increases. This makes GRNN a very useful tool to perform predictions and comparisons of system performance in practice. GRNN is a promising technological tool that can be applied to solve with high efficiency the problems related to neutron spectrometry.

Acknowledgements

This work was partially supported by Fondo Sectorial de Investigación para la Educación under contract 241771, Fondos Mixtos SEP-CONACYT under contract ZAC-C03-2015-26357-4, and PROSOFT under contract 201513723. The first and second authors want to thank the Doctorate

scholarships, with scholarship holder numbers 23386 and 23385, respectively, received by Fondo Sectorial de Investigación para la Educación under contract 241771. The third and fourth authors want to thank the Doctorate scholarships received by Fondos Mixtos SEP-CONACYT under contract ZAC-C03-2015-26357-4. The seventh author want to thank conacyt for the post-doctoral scholarship number 24296. The authors want to thank the active and determined participation and collaboration on several activities on this research project of the undergraduate students: Ana Isabel Ortiz Hernández, Miguel Ángel Acosta García, Fabian García Vázquez, Edgar Viveros Llamas, and Rogelio Osbaldo Reyes Vargas.

Author details

Ma. del Rosario Martínez-Blanco^{1,3}, Víctor Hugo Castañeda-Miranda^{1,3}, Gerardo Ornelas-Vargas^{1,3}, Héctor Alonso Guerrero-Osuna^{1,3}, Luis Octavio Solís-Sánchez^{1,3}, Rodrigo Castañeda-Miranda^{1,3}, José María Celaya-Padilla^{1,3}, Carlos Eric Galvan-Tejada³, Jorge Isaac Galvan-Tejada³, Héctor René Vega-Carrillo⁴, Margarita Martínez-Fierro^{1,5}, Idalia Garza-Veloz^{1,5} and Jose Manuel Ortiz-Rodriguez^{1,3,2*}

*Address all correspondence to: morvymm@yahoo.com.mx

1 Centro de Investigación e Innovación Tecnológica Industrial (CIITI), Universidad Autónoma de Zacatecas, Zacatecas, México

2 Laboratorio de Innovación y Desarrollo Tecnológico en Inteligencia Artificial (LIDTIA), Universidad Autónoma de Zacatecas, Zacatecas, México

3 Unidad Académica de Ingeniería Eléctrica (UAIE), Universidad Autónoma de Zacatecas, Zacatecas, México

4 Unidad Académica de Estudios Nucleares (UAEN), Universidad Autónoma de Zacatecas, Zacatecas, México

5 Laboratorio de Medicina Molecular, Unidad académica de Medicina Humana y Ciencias de la Salud (UAMHCS), Universidad Autónoma de Zacatecas, Zacatecas, México

References

- [1] Fritzsche P. Tools in artificial intelligence. Viena, Austria: InTech; 2008.
- [2] Negnevitsky M. Artificial intelligence, a guide to intelligent systems. Reading, MA, USA: Addison Wesley; 2005.

- [3] Coppin B. Artificial intelligence illuminated. Burlington, MA, USA: Jones and Bartlett Publishers; 2004.
- [4] Russell S.J., Norvig P. Artificial intelligence a modern approach. Mexico: Prentice Hall; 2004.
- [5] Luger G.F. Artificial intelligence structures and strategies for complex problem solving. Reading, MA, USA: Addison-Wesley; 2005.
- [6] Baldi P., Brunak S. Bioinformatics, the machine learning approach. Cambridge, MA, USA: Mit Press; 2001.
- [7] Yu W. Recent advances in intelligent control systems. London: Springer-Verlag; 2009.
- [8] Munakata T. Fundamentals of the new artificial intelligence, neural, evolutionary, fuzzy and more. London: Springer; 2008.
- [9] Chennakesava R.A. Fuzzy logic and neural networks, basic concepts and applications. New Delhi, India: New Age International Publishers; 2008.
- [10] Arbib M.A. Brain theory and neural networks. Cambridge, MA, USA: The MIT Press; 2003.
- [11] Haykin S. Neural networks: a comprehensive foundation. Mexico: Prentice Hall; 1999.
- [12] Zupan J. Introduction to artificial neural network methods: what they are and how to use them. Acta Chimica Slovenica. 1994;41(3):327–352.
- [13] Jain A.K., Mao J., Mohiuddin K.M. Artificial neural networks: a tutorial. IEEE: Computer. 1996;29(3):31–44.
- [14] Lippmann R. An introduction to computing with neural nets. IEEE ASSP Magazine. 1987;4(2):4–22.
- [15] Floreano F., Mattiussi C. Bio-inspired artificial intelligence, theories, methods and technologies. Cambridge, MA, USA: The MIT Press; 2008.
- [16] Gupta M., Jin L., Homma N. Static and dynamic neural networks: from fundamentals to advanced theory. New Jersey, USA: John Wiley Sons; 2003.
- [17] Huang D.S. Radial basis probabilistic neural networks: model and applications. International Journal of Pattern Recognition and Artificial Intelligence. 1999;13(7):1083–1101.
- [18] Mao K., Tan K., Ser W. Probabilistic neural network structure determination for pattern classification. IEEE Transactions on Neural Networks. 2000;11(4):1009–1016.
- [19] Spetch D.F. Probabilistic neural networks for classification, mapping or associative memory. IEEE International Conference on Neural Networks. 1998;1:525–532.
- [20] Spetch D.F. Probabilistic neural networks. Neural Networks. 1990;3(1):109–118.

- [21] Spetch D.F. Enhancements to probabilistic neural networks. *International Joint Conference on Neural Networks*. 1992;1:761–768.
- [22] Taylor J.G. *Mathematical approaches to neural networks*. Holland: North-Holland Mathematical library; 1993.
- [23] Spetch D.F., Romsdhal H. Experience with adaptive probabilistic neural networks and adaptive general regression neural networks. *IEEE International Conference on Neural Networks*. 1994;2:1203–1208.
- [24] Spetch D.F., Shapiro P. Generalization accuracy of probabilistic neural networks compared with backpropagation networks. *IJCNN-91-Seattle International Joint Conference on Neural Networks*. 1991;1:887–892.
- [25] Attix F.H. *Introduction to radiological physics and radiation dosimetry*. New Jersey, USA: Wiley-VCH; 2004.
- [26] Lilley J. *Nuclear physics, principles and applications*. New Jersey, USA: John Wiley & Sons, Ltd.; 2001.
- [27] Bromley D.A. Detectors in nuclear science. *Nuclear Instruments and Methods*. 1979;162:431–476.
- [28] Bramblett R.L., Ewing R.I., Bonner T.W. A new type of neutron spectrometer. *Nuclear Instruments and Methods*. 1960;9:1–12.
- [29] Thomas D.J. Neutron spectrometry for radiation protection. *Radiation Protection Dosimetry*. 2004;110(1–4):141–149.
- [30] Matzke M. Unfolding procedures. *Radiation Protection Dosimetry*. 2003;107(1–3):155–174.
- [31] Braga C.C., Dias M.S. Application of neural networks for unfolding neutron spectra measured by means of Bonner spheres. *Nuclear Instruments and Methods in Physics Research Section A*. 2002;476(1–2):252–255.
- [32] Kardan M.R., Setayeshi S., Koochi-Fayegh R., Ghiassi-Nejad M. Neutron spectra unfolding in Bonner spheres spectrometry using neural networks. *Radiation Protection Dosimetry*. 2003;104(1):27–30.
- [33] Kardan M.R., Koochi-Fayegh R., Setayeshi S., Ghiassi-Nejad M. Fast neutron spectra determination by threshold activation detectors using neural networks. *Radiation Measurements*. 2004;38:185–191.
- [34] Vega-Carrillo H.R., et al. Neutron spectrometry using artificial neural networks. *Radiation Measurements*. 2006;41:425–431.
- [35] Vega-Carrillo H.R., Martinez Blanco M.R., Hernandez Davila V.M., Ortiz Rodriguez J.M. Ann in spectroscopy and neutron dosimetry. *Journal of Radioanalytical and Nuclear Chemistry*. 2009;281(3):615–618.

- [36] Ortiz-Rodriguez J.M., Martinez-Blanco H.R., Vega-Carrillo H.R. Robust design of artificial neural networks applying the Taguchi methodology and DoE. Proceedings of the Electronics, Robotics and Automotive Mechanics Conference (CERMA'06), IEEE Computer Society. 2006;1:1-6.
- [37] IAEA. Compendium of neutron spectra and detector responses for radiation protection purposes. Technical Report 403; Vienna, Austria: International Atomic Energy Agency (IAEA); 2001.

INTECH

INTECH



ELSEVIER

Contents lists available at ScienceDirect

Applied Radiation and Isotopes

journal homepage: www.elsevier.com/locate/apradiso

A comparison of back propagation and Generalized Regression Neural Networks performance in neutron spectrometry

Ma. del Rosario Martínez-Blanco^{a,b,c,d}, Gerardo Ornelas-Vargas^{a,b,c,d},
Luis Octavio Solís-Sánchez^{a,b,c,d}, Rodrigo Castañeda-Miranada^{a,b,c,d},
Héctor René Vega-Carrillo^{b,c,d,e}, José M. Celaya-Padilla^{a,c}, Idalia Garza-Veloz^{a,b,c,f},
Margarita Martínez-Fierro^{a,b,c,f}, José Manuel Ortiz-Rodríguez^{a,b,c,d,*}

^a Universidad Autónoma de Zacatecas, Centro de Investigación e Innovación Tecnológica Industrial (CIITI), Av. Ramón López Velarde, 801, Col. Centro, 98000 Zacatecas, México

^b Universidad Autónoma de Zacatecas, Grupo de Investigación Regional Emergente (GIRE), Av. Ramón López Velarde, 801, Col. Centro, 98000 Zacatecas, México

^c Universidad Autónoma de Zacatecas, Laboratorio de Innovación y Desarrollo Tecnológico en Inteligencia Artificial (LIDTIA), Av. Ramón López Velarde, 801, Col. Centro, 98000 Zacatecas, México

^d Universidad Autónoma de Zacatecas, Unidad Académica de Ingeniería Eléctrica (UAIE), Av. Ramón López Velarde, 801, Col. Centro, 98000 Zacatecas, México

^e Universidad Autónoma de Zacatecas, Unidad Académica de Estudios Nucleares (UAEN), C. Cipres 10 Fracc. La Penuela 98068 Zacatecas, Mexico

^f Universidad Autónoma de Zacatecas, Laboratorio de Medicina Molecular, Unidad Académica de Medicina Humana y Ciencias de la Salud, Campus UAZ siglo XXI, Carretera Zacatecas-Guadalajara Km 6 Ejido la Escondida CP. 98160. Zacatecas, México

ARTICLE INFO

Article history:

Received 19 October 2015

Received in revised form

15 April 2016

Accepted 15 April 2016

Available online 19 April 2016

Keywords:

Neutron spectrometry

Artificial Neural Networks

Unfolding

Comparison

ABSTRACT

The process of unfolding the neutron energy spectrum has been subject of research for many years. Monte Carlo, iterative methods, the bayesian theory, the principle of maximum entropy are some of the methods used. The drawbacks associated with traditional unfolding procedures have motivated the research of complementary approaches. Back Propagation Neural Networks (BPNN), have been applied with success in neutron spectrometry and dosimetry domains, however, the structure and learning parameters are factors that highly impact in the networks performance. In ANN domain, Generalized Regression Neural Network (GRNN) is one of the simplest neural networks in term of network architecture and learning algorithm. The learning is instantaneous, requiring no time for training. Opposite to BPNN, a GRNN would be formed instantly with just a 1-pass training on the development data. In the network development phase, the only hurdle is to optimize the hyper-parameter, which is known as sigma, governing the smoothness of the network. The aim of this work was to compare the performance of BPNN and GRNN in the solution of the neutron spectrometry problem. From results obtained it can be observed that despite the very similar results, GRNN performs better than BPNN.

© 2016 Elsevier Ltd. All rights reserved.

1. Introduction

Neutron spectrometry is not a trivial problem. The derivation of the spectral information is hard because the unknown is not given directly as result of measurements. The derivation of the spectral

* Corresponding author at: Universidad Autónoma de Zacatecas, Laboratorio de Innovación y Desarrollo Tecnológico en Inteligencia Artificial (LIDTIA), Av. Ramón López Velarde, 801, Col. Centro, 98000 Zacatecas, México.

E-mail addresses: mrosariomb@yahoo.com.mx (Ma.d.R. Martínez-Blanco), ornelashlls@gmail.com (G. Ornelas-Vargas), l_solis@ymail.com (L.O. Solís-Sánchez), rcastm@gmail.com (R. Castañeda-Miranada), fermineutron@yahoo.com (H.R. Vega-Carrillo), jose.cpadilla@gmail.com (J.M. Celaya-Padilla), idgarve@gmail.com (I. Garza-Veloz), margaritamf@uaz.edu.mx (M. Martínez-Fierro), morvymmm@yahoo.com.mx (J.M. Ortiz-Rodríguez).

<http://dx.doi.org/10.1016/j.apradiso.2016.04.011>

0969-8043/© 2016 Elsevier Ltd. All rights reserved.

information is an ill-posed problem (Vega-Carrillo et al., 2005), it is derived through the discrete version of the Fredholm integral-differential equation of first type (Thomas, 2004). The system of equations that derives the spectral information have no explicit solution, and may have no unique solution. Normally, researchers solve a discrete version of this equation, which gives an ill-conditioned system of equations (Thomas and Alevra, 2002).

Since 60's years, the Bonner Sphere Spectrometer (BSS) has been the most widely used method for radiological protection purposes (Bonner, 1961). The isotropy of the response, the wide energy range (from thermal to GeV neutrons) and the easy operation make these systems still applicable (Thomas and Alevra, 2002). BSS consists of a thermal neutron detector located at the center of several high density polyethylene spheres of different diameters (Alevra et al., 1992). By measuring the count rate of each

sphere individually, an unfolding process can, in principle, provide some information about the energy distribution of the incident neutrons (Matzke and Weise, 1985a).

However, the most delicate part of neutron spectrometry based on BSS is the unfolding process (Matzke, 2003). The unfolding spectrum of the measured neutrons consist on establishing the rate of energy distribution of fluency, known as response matrix, and the group of measures carried out (Lferde et al., 2004). Because the number of unknowns overcome the number of equations, this ill-conditioned system has an infinite number of solutions (Vega-Carrillo et al., 2006). The process of selecting a meaningful solution for the problem is part of the unfolding process.

To solve the system of equations for BSS unfolding, several approaches have been used: iterative procedures (Miller, 1993; Hertel et al., 2002), Monte Carlo methods (Matzke and Weise, 1985b; Sanna and O'brien, 1971), regularization and maximum entropy methods (Goldagen et al., 2002). However, the drawbacks associated with these traditional unfolding procedures have motivated the research of complementary approaches. Novel methods based on Artificial Intelligence (AI) have been suggested (Kardan, et al., 2003; Braga and Dias, 2002; Freeman et al., 1999; Vega-Carrillo et al., 2005; Vega-Carrillo, et al., 2006; Vega-Carrillo et al., 2007, 2009a, 2009b, 2009a, 2009b, 2010).

In neutron spectrometry, the theory of Artificial Neural Networks (ANN) has offered a promising alternative to the classic calculations over traditional methods (Vega-Carrillo et al., 2005, 2007, 2009a, 2009b, 2009a, 2009b, 2010; Vega-Carrillo et al., 2006). Neural networks are large structured systems of equations (Galushkin, 2007; Arbib, 2003; Mehrotra et al., 1997; Graupe, 2007; Dreyfus, 2005; Fausett, 1993). These systems have many degrees of freedom and are able to adapt to the task they are supposed to do (Gupta et al., 2003). Generally, there are two very different types of neural networks: Back-Propagation Neuronal Networks (BPNN) and Probabilistic neural networks (PNN) (Huang, 1999; Mao et al., 2000; Chtioui et al., 1997).

BPNN have been the most popular networks used in neutron spectrometry (Braga and Dias, 2002; Kardan et al., 2003; Sara et al., 2006; Vega-Carrillo et al., 2006; Vega-Carrillo et al., 2010, 2009a, 2009b, 2009a, 2009b, 2007, 2005). BPNN use equations that are connected using weighted factors. The selection of this factors make these neural networks so powerful. However, BPNN uses methods that are not based on statistical methods and take long time, many iterations and feedbacks until it gradually approaches the underlying function (Chtioui et al., 1997). The learning of BPNN can be described as trial and error. This is no longer the case of the PNN. The experience is learned not by trial but by experience others made for the neural network (Zhao et al., 2002).

PNN use a statistical approach in their prediction algorithm (Zhao et al., 2002; Mao et al., 2000) (Huang, 1999). The bases for the statistical approach are given in the Bayes strategy for pattern classification (Specht et al., 1991; Specht and Donald, 1992; Specht et al., 1994; Specht and Donald, 1990, 1988). These strategies can be applied to problems containing any number of categories as in the case of the neutron spectrometry problem. To be able to use the Bayes strategy is necessary to estimate the probability density function accurately. The only available information to estimate the density functions are the training samples.

Opposite to BPNN, PNN use statistical methods to select the equations within the structure and do not weight these functions differently. The Bayes strategy for pattern classification, in which PNN is based, extracts characteristics from the training samples to unfold the knowledge about the underlying function.

The aim of this work, was to compare the performance of BPNN and PNN architectures aiming to solve the neutron spectrometry problem. Results obtained shows that the two architectures solve

the neutron spectrometry problem well, with high performance and generalization capabilities, however, Generalized Regression Neural Network (GRNN) outperform BPNN, mainly because GRNN does not produce negative values and oscillations around the target value.

2. Materials and methods

An ANN is a network of simple processing nodes, which is roughly modeled on the human brain (Cheng et al., 1994; Haykin, 2004). ANN consists of a number of nodes, each of this nodes can be thought of as neuron representation (Arbib, 2003; Hornik, 1989). Typically, the network is arranged such that one layer is the input layer, which receives inputs that are yet to be classified (Fausett, 1993). These inputs activate some of the neurons in the input layer, then, those neurons pass signals to the connected neurons, afterwards, the process is repeated in the next layer. In this way, a complex pattern of activations is arranged throughout the network, with final result being that some neurons in the final output layer activate (Dreyfus, 2005).

The connection between neurons are weighted, and by modifying these weights, the neural network can be arranged to perform extremely complex classification tasks such as handwriting analysis (Rehman, 2014), face recognition (Graupe, 2013) or to solve the neutron spectrometry problem.

2.1. Back-propagation neural networks

BPNN consist of neurons organized in one input layer, one output layer and several hidden layer of neurons (Apolloni et al., 2009). Neurons perform some kind of calculation. They use inputs to compute an output that represent the system (Mehrotra et al., 1997). The outputs are then passed to a connecting neuron (Galushkin, 2007). A line indicates to which neuron the output is connected. These lines carry synaptic weights.

Fig. 1 shows the structure of a BPNN. The input vector consists of variables that are used to predict the desired output (that solves the problem being analyzed). The inputs could be for example, the rates count measured with the BSS and the outputs could be the unfolded neutron spectrum.

As can be observed from Fig. 1, the information is given on to the next neuron. Each neuron receives signals coming from n neurons of the m_{j-1} layer, where m_j is the current layer. Each signal is weighted as it is given from the input layer to the first hidden layer. As the new signals reaches a connecting neuron in the hidden layer, all the signals are received by the neuron and are summed up. This process can be seen as a multiplication vector of the weights vector w and the signal vector $y_{previous}$ of the previous layer. In the hidden layer new signals are computed and given on to the next hidden layer. This process continues until the output layer is reached (Fig. 2).

The previous process in the neural network is repeated. The values of the signals along with weights will be different but the process itself will continue similarly. The signals are weighted and then summed up, they cause a reaction of the neuron and the reaction, which is the new signal, will be given on to the next neuron.

The last step is to give the signal to the output layer. The output layer can consist of one or more neurons. More neurons mean that the plane of the neural network has multiple outputs. In the output neuron a calculation is necessary to yield a value that is not normalized in order to have a physical meaning.

One characteristic of BPNN is that they are very flexible. They can be used to solve different problems. Another advantage is that the process is highly parallel, however, BPNN have some

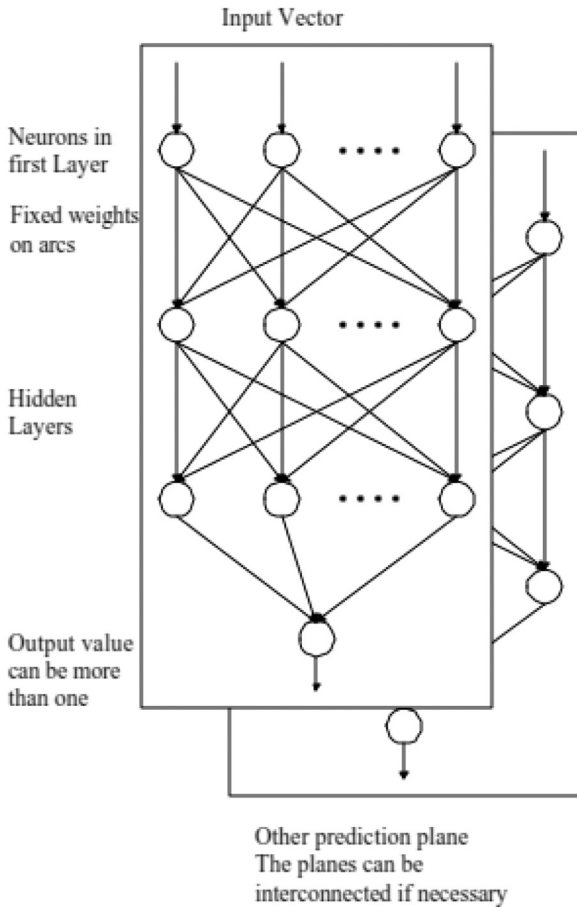


Fig. 1. BPNN architecture.

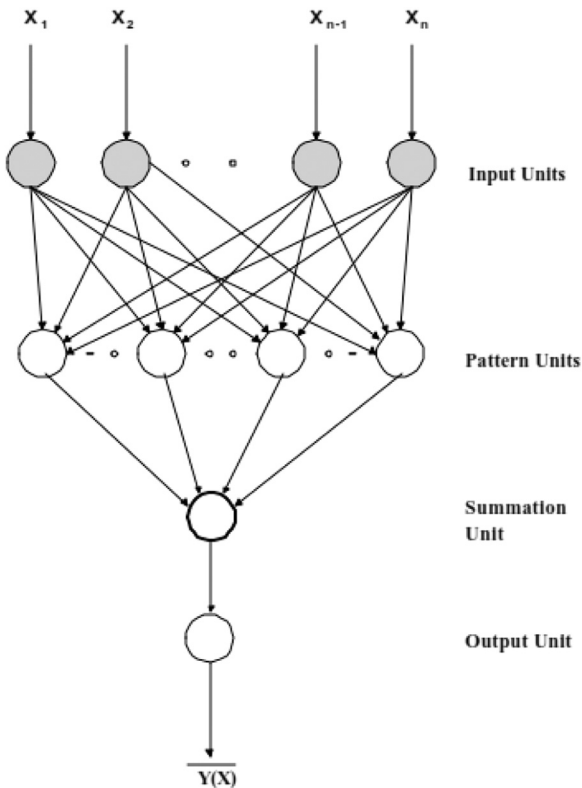


Fig. 2. GRNN architecture.

drawbacks (Ortiz-Rodríguez et al., 2006; Martínez-Blanco et al., 2006). The structural and learning parameters of the network are often determined using the trial and error technique. This produces networks with poor performance and low generalization capabilities affecting the application of the trained networks in real applications. The training stage can be time consuming in order to gradually approach good values of the weights. The size of the training data has to be very large, thus, often it is almost impossible to provide enough training samples as in the case of the neutron spectrometry problem. Another drawback is that adding new information requires retraining the network and this is computationally expensive for BPNN but not for PNN (Chitioui et al., 1997). PNN have the big advantage that the prediction algorithm works with only few training samples (Specht et al., 1991). Other big advantage is that they are very flexible and new information can be added immediately with almost no retraining.

The learning of BPNN can be described as trial and error. A GRNN has certain differences compared to an BPNN approach (Specht and Donald, 1992). The experience is learned not by trial, is learned by experience others made for the neural network. The biggest advantage is the fact that the probabilistic approach works with one-step-only learning.

2.2. Generalized Regression Neural Networks

GRNN belong to PNN classification. These neural networks use a statistical approach in their prediction algorithm (Specht and Donald, 1990, 1988, 1992). The bases for the statistical approach are given in the Bayes strategy for pattern classification. These strategies can be applied to problems containing any number of categories as in the case of the neutron spectrometry problem. In order to use the Bayes strategy, it is necessary to accurately estimate the probability density function (PDF) (Specht and Donald, 1992). The only available information to estimate the PDF are the training samples. The structure of the calculations for the probabilistic density function has striking similarities to BPNN.

The general structure of GRNN (Zhao et al., 2002) consists of; one input layer and two hidden layers. The first hidden layer contains the pattern units. Each pattern unit represents information on one string sample. Each pattern unit calculates the probability on how well the input vector fits into the pattern unit. In the second hidden layer there is only one summation unit. Here it is decided upon the individual results of each pattern unit in which pattern the input vector finally belongs. The output unit performs again a calculation to give the output which is physically meaningful.

A further difference that exists between BPNN and GRNN is the difference in the process inside the neurons (Zhao et al., 2002; Specht et al., 1991; Specht and Donald, 1988). A GRNN use functions that are based on knowledge resulting from the Bayes strategy for pattern classification. The strength of a probabilistic neural network relay in the function that is used inside the neuron.

In this work, a comparison of the performance obtained in the solution of the neutron spectrometry problem using two different neural network architectures, BPNN and GRNN, is presented. Both, BPNN and GRNN, were trained and tested using the same information: two hundred and fifty-one neutron spectra, extracted from IAEA's compilation. 80% of the whole data set was randomly selected as a training set, the remaining 20% was used as a testing set. 50 neutron spectra were used as testing data set.

The architectural and learning parameters of the BPNN were optimized using a statistical methodology known as Robust Design of Artificial Neural Networks Methodology (RDANNM) (Ortiz-Rodríguez et al., s.f.). In GRNN the only parameter determined was the spread constant value, known as sigma. Customized scientific

computational tools were used for the training, testing, analysis and storing of the information generated in the whole process. From results obtained it can be observed that despite two networks architectures shown very similar performance and generalization capabilities, GRNN perform better than BPNN in the solution of the neutron spectrometry problem. BPNN produce negative values and high oscillations around the target values, which makes this type of network not useful in the solution of the problem mentioned.

3. Results

By using the RDANNM, 50 different network architectures were trained in an average of 150 min, before the selection of the near optimum architecture. By testing different network architectures according RDANNM, each network was trained in 50E3 epochs and 180 s average, stopping the training when the network reached the established mean square error (mse) equal to 1E-4, value used to measure the network performance. After selecting the near optimum architectural and learning parameters of the BPNN, the network was trained and tested using the following values: one hidden layer with 10 neurons, a *trainscg* training algorithm and a learning rate and momentum equal to 0.1 and 0.01 respectively, a detail description is presented in Table 1.

Opposite to BPNN, the spread constant (σ) was the only value determined in GRNN. Using the same training and testing data sets used for BPNN, 2000 neural networks were trained in an average of 154 s, in order to determine the spread constant equal to 0.2711. Each GRNN was trained in 0.058 s average in only one-step-only learning.

Table 1 shows the obtained values after training the two networks architectures being compared in this work. As can be seen, when the trial-and-error technique is used it is very difficult to determine if the performance of the network is good or bad, mainly because is not used a scientific and systematic methodology for determining the near optimum learning and architectural values as when RDANNM is used.

Table 1
Comparison between BPNN and GRNN values in neutron spectrometry.

Network parameters	BPNN [trial and error]	BPNN [RDANNM]	GRNN
Networks tested before training	Undetermined	50 in 150 min	2000 in 154 s
Hidden layers	Undetermined	1	Fixed architecture
Neurons in hidden layer	Undetermined	10	According input
Training algorithm	Undetermined	Trainscg	Statistical methods
Learning rate	Undetermined	0.1	–
Momentum	Undetermined	0.01	–
Spread constant	–	–	0.2711
Performance [mse]	Undetermined	2.12E-4	2.48E-4
Training time [s]	Several hours	170.40	0.058
Epochs	Often millions	50E3	1
Best Chi-square test BPNN		2.3525	0.049
Statistical margin 34.7			
Best Correlation test BPNN		0.9928	0.99571
Statistical margin 1			
Worst Chi-square test BPNN		0.44704	0.3223
Worst Correlation test BPNN		0.2926	0.46023

As is shown in Table 1, after training both network architectures, BPNN optimized using RDANNM and GRNN, the performance measured by mse reached by the two networks is very similar between both strategies. In BPNN networks, the mse is a value optimized by the network designer using RDANNM, in a GRNN network the value is automatically obtained by the network based on the training information. Said differences, demonstrates the powerful of RDANNM in the optimization of the near optimum values of BPNN architectures.

Fig. 3 shows that at testing stage, the chi-square and correlation tests are very close in both, BPNN and GRNN network architectures. The same 50 neutron spectra were used for testing the two networks. At testing stage, only the count rates were fed to the trained networks. The output produced by the networks was compared with the expected neutron spectrum taken from IAEA's compilation by means of chi-square and correlation tests. In the trained networks, two spectra are above the statistical margin of the chi-square test. In correlation tests, both BPNN and GRNN obtained 0.2926 and 0.46023 respectively. This shows the high performance of the networks.

As can be seen from Fig. 3, the 50 chi-square and correlation tests of trained networks are very similar. In both cases the average value is around 0 and 0.8 respectively, which is near of the optimum values equal to 0 and 1. This demonstrate the high performance of BPNN and GRNN, generalization capabilities, and demonstrates the effectiveness of the RDANNM in the design of near optimum architectures of BPNN.

As before mentioned, 50 neutron spectra were randomly selected at testing stage. The same training and testing data sets were used to train and to test the performance and generalization capabilities of the networks. The best and the worst cases for both, BPNN and GRNN, are showed in Figs. 4–7. Figs. 4 and 5 show the best cases observed at testing stage for BPNN and GRNN respectively. From these figures it can be observed that the chi-square test for both, BPNN and GRNN, are 2.3525 and 0.0490 respectively, the correlations for BPNN and GRNN are 0.9928 and 0.99571 respectively, which means that the compared neutron spectra are very similar.

As can be appreciated in Figs. 4–7, despite the good results obtained with BPNN, one drawback is that the calculated neutron spectra produce negative values, said values have no meaning in real problems. These negative values are eliminated from the output produced by the network, however, when the BPNN is applied in real workplaces, Due the training received, the network tends to produce negative values and oscillations around the target value. GRNN networks do not produce these negative values and oscillations, therefore the performance is better than BPNN in the solution of the neutron spectrometry problem.

Figs. 6 and 7 show the worst case observed at testing stage for BPNN and GRNN networks respectively. As can be seen from these figures both, BPNN and GRNN, selected the same neutron spectra as the worst. This could be because the 50 energy bins that the neural networks calculate, 49 values are very similar and only one value is far from the expected target value, this causes that the chi-square and correlation tests produce low values. From Figs. 6 and 7 can be observed that in the GRNN architecture the output is closer than the target values of the neutron spectra when compared with BPNN. This shows that in the worst case, GRNN outperformance BPNN.

4. Discussion

Statistical methods tend to emphasis on the structure of the data. For neural network methods the structure of the data is secondary. Therefore, the amount of data needed for statistical

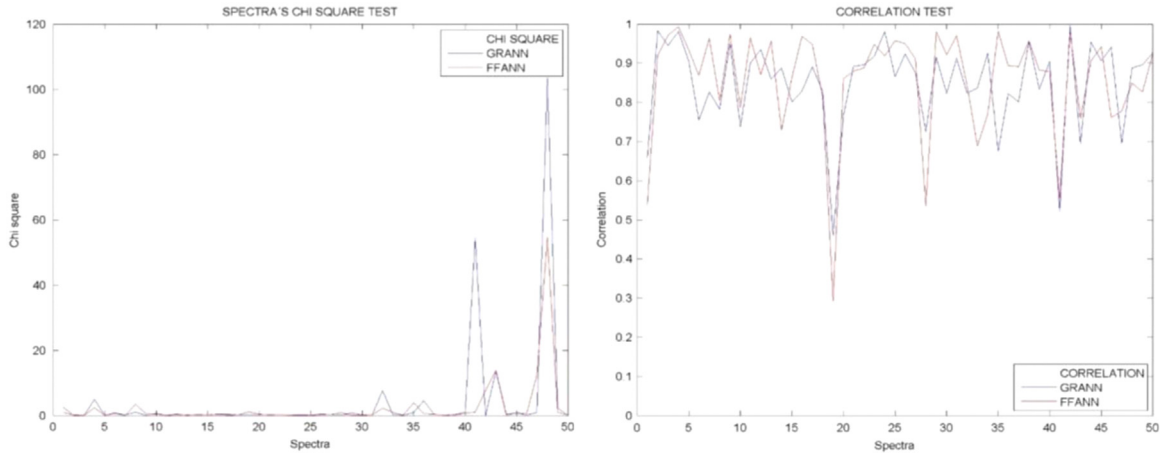


Fig. 3. Chi-square and correlation tests comparison for BPNN and GRNN.

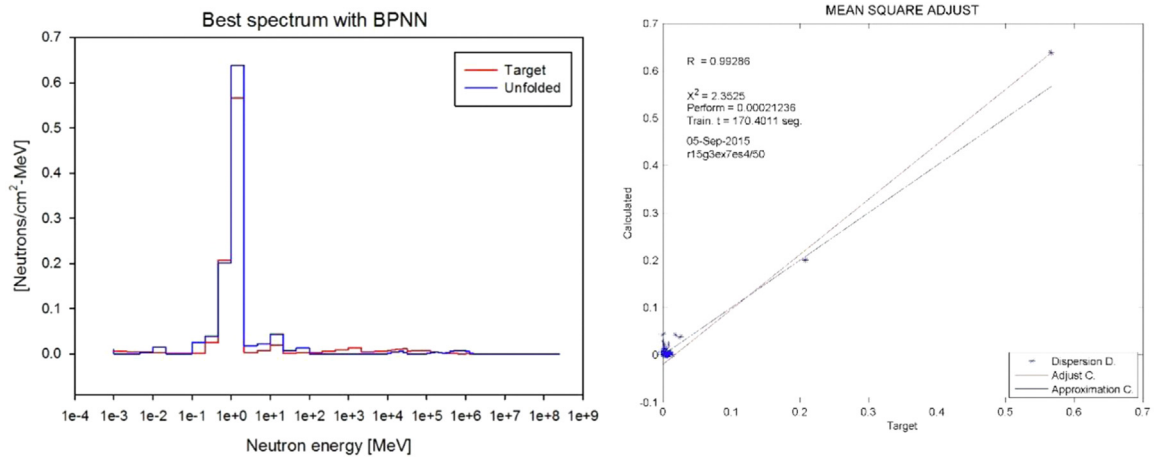


Fig. 4. Best chi-square and correlation tests obtained with BPNN.

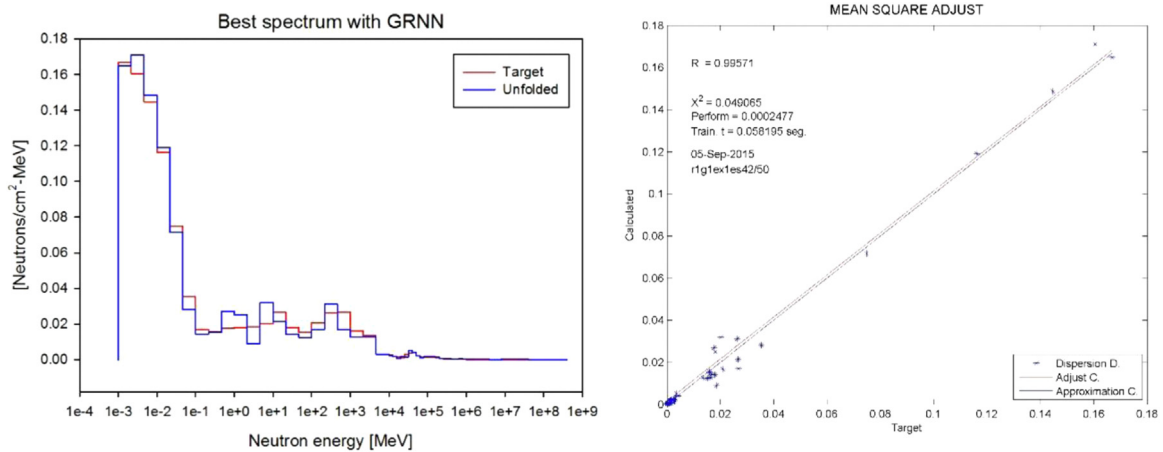


Fig. 5. Best chi-square and correlation tests obtained with GRNN.

methods is a smaller than the amount of data needed for ANN approaches.

Most methods are asymptotically good, nevertheless most of them have severe drawbacks as well. BPNN need a large number of training samples and the weights refinement is time consuming. Adding of new information requires retraining and this is computationally expensive for BPNN but not for PNN. PNN have the big advantage that the prediction algorithm works with only a few training samples. Other advantage is that they are very flexible and

new information can be added immediately with almost no retraining.

PNN use a statistical approach in their prediction algorithm. The bases for the statistical approach are given in the Bayes strategy for pattern classification. These strategies can be applied to problems containing any number of categories as in the case of the neutron spectrometry problem. To be able to use the Bayes strategy it is necessary to estimate the probability density function accurately. The only available information to estimate the density

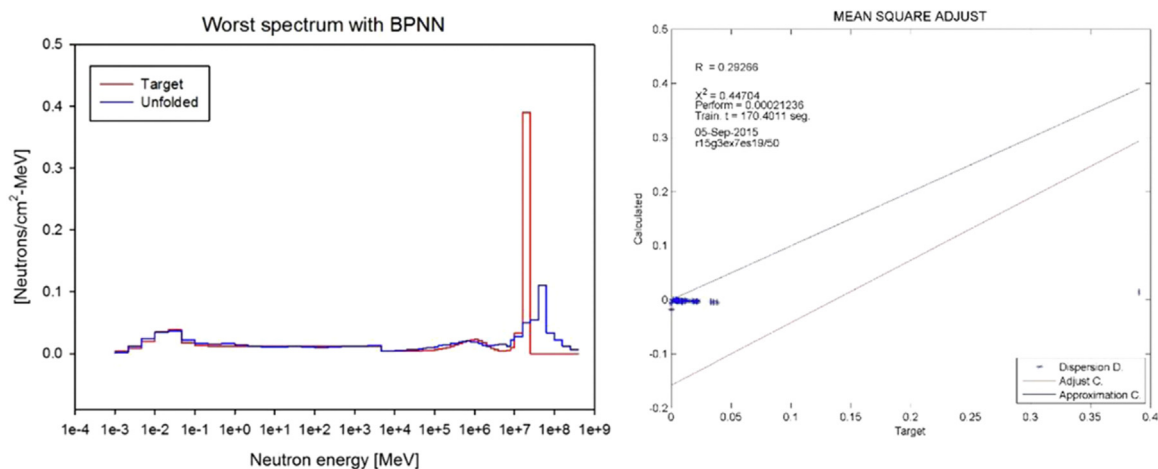


Fig. 6. Worst chi-square and correlation tests obtained with BPNN.

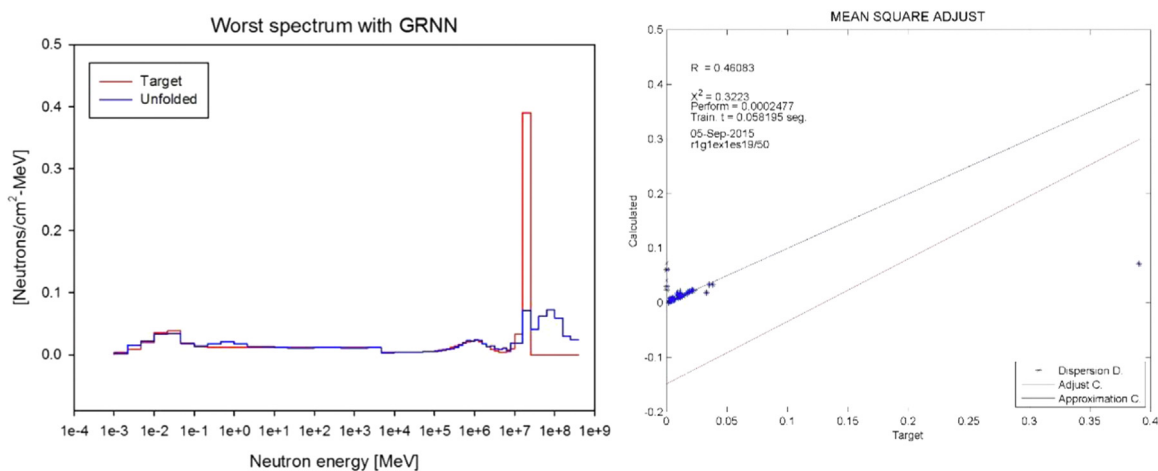


Fig. 7. Worst chi-square and correlation tests obtained with GRNN.

functions are the training samples.

The structure of the calculations for the PDF has striking similarities to a back-propagation feed-forward neural network. PNN are frequently used to classify patterns based on learning from examples. PNN algorithm uses the Bayes strategy for pattern classification. Different rules determine patterns statistics from the training samples. BPNN uses methods that are not based on statistical methods and need a long time to compute and many iterations and feedbacks until it gradually approaches the underlying function. It would be desirable to approach the parameters in one-step-only approach. The Bayes strategy for pattern classification extracts characteristics from the training samples to come to knowledge about underlying function.

5. Conclusions

In this work, two different Artificial Neural Networks architectures, BPNN and GRNN, were trained and tested using the same information. The performance of the networks was compared. From results obtained it can be observed that GRNN perform better than BPNN in the solution of the neutron spectrometry problem.

Different approaches exist to model a system with the data available. Each one of them has its very own qualities and therefore advantages. GRNN falls into the category of PNN. This neural network like other PNNs needs only a fraction of the training

samples as a BPNN would need. The data available from measurements of an operating system is generally never enough for a BPNN. Therefore, the use of GRNN is especially advantageous due to its ability to converge to the underlying function of the data with only few training samples available. The additional knowledge needed to fitting in a satisfying way is relatively small and can be done without additional input by the user.

PNN have a very simple structure, therefore very stable procedures. PNN perform very well for even only a few available training samples, nevertheless the quality increases as the number of training samples increases. This makes GRNN a useful tool to perform predictions and comparisons of system performance in practice. GRNN is a promising technological tool that can be applied to solve with high efficiency problems related with neutron spectrometry.

Acknowledgments

This work was partially supported by Fondo Sectorial de Investigación para la Educación under contract 241771.

This work was partially supported by Fondos Mixtos SEP-CONACYT under contract ZAC-C03-2015-26357-4.

This work was partially supported by PROSOFT under contract 201513723.

The first author want to thank the Doctorate scholarship, with scholarship holder number 23386, received by Fondo Sectorial de

Investigación para la Educación under contract 241771.

The second author want to thank the Doctorate scholarship, received by Fondos Mixtos SEP-CONACYT under contract ZAC-C03-2015-26357-4.


References

- Alevra, A.V., Cosack, M., Hunt, J.B., Thomastli, D.J., Schraube, H., 1992. Experimental determination of the response of four Bonner sphere sets to monoenergetic neutrons (II). *Radiat. Prot. Dosim.* 40 (2), 91–102.
- Apolloni, B., Bassis, S., Marinaro, M., 2009. *New Directions in Neural Networks*. IOS Press.
- Arbib, M., 2003. *Brain Theory and Neural Networks*. The MIT Press.
- Bonner, T., 1961. Measurements of neutron spectra from fission. *Nucl. Phys.* 23, 116–121.
- Braga, C., Dias, M., 2002. Application of neural networks for unfolding neutron spectra measured by means of Bonner spheres. *Nucl. Instrum. Methods Phys. Res. Sect. A* 476 (1–2), 252–255.
- Cheng, B., Titterton, D., 1994. Neural networks: a review from a statistical perspective. *Static Sci.* 9 (1), 2–30.
- Chtioui, Y., Dominique, B., Marie-Francoise, D., Dominique, B., 1997. Comparison of multilayer perceptron and probabilistic neural networks in artificial vision. Application to the discrimination of seeds. *J. Chemom.* 11 (2), 111–129.
- Dreyfus, G., 2005. *Neural Networks Methodology and Applications*. Springer.
- Fausett, L., 1993. *Fundamentals of Neural Networks*, 1st ed. Prentice Hall.
- Freeman, D., Edwards, D., Bolon, A., 1999. Genetic Algorithms a New Technoqe for Solving a Neutron Spectrum Unfolding Problem. *Nucl. Instrum. Methods Phys. Res. Sect. A* 425 (3), 549–576.
- Galushkin, A., 2007. *Neural Networks Theory*. Springer.
- Goldagen, P., Reginatto, M., Neumann, S., 2002. Spectrum Unfolding Sensitive Analysis and Propagation of Uncertainties with the Maximum Entropy Deconvolution Code MAXED. *Nucl. Instrum. Method Phys. Res. Sect. A* 476, 242–246.
- Graupe, D., 2007. *Principles of Artificial Neural Networks*. World Scientific.
- Graupe, D., 2013. *Principles of Artificial Neural Networks*. World Scientific.
- Gupta, M., Jin, L., Homma, N., 2003. *Static and Dynamic Neural Networks: From Fundamentals to Advanced Theory*. John Wiley Sons, Inc.
- Haykin, S., 2004. *A comprehensive foundation*. Neural Netw.
- Hertel, N., Sweezy, J., Veinot, K., 2002. BUMS Bonner sphere unfolding made simple an: HTML based multisphere neutron spectrometer unfolding package. *Nucl. Instrum. Methods Phys. Res. Sect. A* 476, 263–269.
- Hornik, K., 1989. Multilayer feedforward networks are universal approximators. *Neural Netw.*, 359–366.
- Huang, D.-S., 1999. Radial basis probabilistic neural networks: model and applications. *Int. J. Pattern Recognit. Artif. Intell.* 13 (7), 1083–1101.
- Kardan, M., Setayeshi, S., Koochi-Fayeg, R., Ghiassi-Nejad, M., 2003. Neutron spectra unfolding in Bonner spheres spectrometry using neural networks. *Radiat. Prot. Dosim.* 104 (1), 27–30.
- Lferde, M., Chouak, A., El Messaudi, M., Cherkaoui, R., 2004. Performance of three different unfolding procedures connected to Bonner sphere data. *Radiat. Prot. Dosim.* 108 (3), 247–253.
- Mao, K., Tan, K., Ser, W., 2000. Probabilistic neural-netwok structure determination for pattern classification. *IEEE Trans. Neural Netw.* 11 (4), 1009–1016.
- Martínez-Blanco, M., Ortiz-Rodríguez, J., Vega-Carrillo, H., 2006. Espectrometría de neutrones y cálculo de dosis equivalentes aplicando la metodología de diseño robusto de redes neuronales artificiales. *IEEE Comput. Soc. 00*, 301–306.
- Matzke, M., 2003. Unfolding procedures. *Radiat. Prot. Dosim.* 107 (1–3), 155–175.
- Matzke, M., Weise, K., 1985a. Neutron spectrum unfolding by the Monte Carlo Method. *Nucl. Instrum. Methods Phys. Res. Sect. A* 234, 324–330.
- Matzke, M., Weise, K., 1985b. Neutron spectrum unfolding by the Monte Carlo Method. *Nucl. Instrum. Methods Phys. Res. Sect. A* 234, 324–330.
- Mehrotra, C., Mohan, K., Ranka, S., 1997. *Elements of Artificial Neural Networks*. MIT Press.
- Miller, S., 1993. AFITBUNKI: A Modified Iterative Code to Unfol Neutron Spectra from Bonner Sphere Detector Data. s.l.:s.n.
- Ortiz-Rodríguez, J., Martínez-Blanco, M., Cervantes-Viramontes, J., Vega-Carrillo, H., s.f. Robust design of artificial neural networks methodology in neutron spectrometry. In: Suzuki, K. (Ed). *Artificial Neural Networks – Architectures and Applications*. s.l.:InTec.
- Ortiz-Rodríguez, J., Martínez-Blanco, M., Vega-Carrillo, H., 2006. Robust design of artificial neural networks applying the taguchi methodology and DoE. In: *Proceedings of the Electornics, Robotics and Automotive Mechanics Conference (CERMA'06)*, pp. 131–136.
- Rehman, A., 2014. Neural networks for document image preprocessing: state of the art. *Artif. Intell. Rev.*, 253–273.
- Sanna, R., O'Brien, K., 1971. Monte Carlo unfolding of neutron spectra. *Nucl. Instrum. Methods* 91, 573–576.
- Sara, A., Senada, A., Vladimir, P., 2006. Detector response unfolding using artificial neural networks. *Nucl. Instrum. Methods Phys. Res. Sect. A* 565, 742–752.
- Specht, Donald, F., 1988. Probabilistic neural networks for classification, mapping, or associative memory. *IEEE International Conference on Neural Networks*, vol. 1, pp. 525–532.
- Specht, Donald, F., 1990. Probabilistic neural networks. *Neural Netw.* 3 (1), 109–118.
- Specht, Donald, F., 1992. Enhancements to probabilistic neural networks. *International Joint Conference on Neural Networks*, vol. 1, pp. 761–768.
- Specht, Donald, F., Romsdahl, H., 1994. Experience with adaptative probabilistic neural networks and adaptive general regression neural networks. *IEEE International Conference on Neural Networks*, vol. 2, pp. 1203–1208.
- Specht, Donald, F., Shapiro, P., 1991. Generalization Accuracy of Probabilistic Neural Networks Compared with Backpropagation Networks. *IJCNN-91-Seattle Intrnational Joint Conference on Neural Networks*, vol. 1, pp. 887–892.
- Thomas, D., 2004. Neutron spectrometry for radiation protection. *Radiat. Prot. Dosim.* 110 (1–4), 141–149.
- Thomas, D., Alevra, A., 2002. Bonner sphere spectrometers – a critical review. *Nucl. Instrum. Methods Phys. Res. Sect. A* 476, 12–20.
- Vega-Carrillo, H.R., Hernández-Dávila, V.M., Manzanares-Acuña, E., Gallego, E., Lorente, A., Iñiguez, M.P., 2007. Artificial neural networks technology for neutron spectrometry and dosimetry. *Radiat. Prot. Dosim.* 126 (1–4), 408–412.
- Vega-Carrillo, H.R., Hernández-Dávila, V.M., Manzanares-Acuña, E., Mercado, G.A., Gallego, E., Lorente, A., Perales-Muñoz, W.A., Robles-Rodríguez, J.A., 2005. Artificial neural networks in neutron dosimetry. *Radiat. Prot. Dosim.* 118 (3), 251–259.
- Vega-Carrillo, H., Martínez-Blanco, M., Hernandez-Davila, V., Ortiz-Rodríguez, J., 2009a. ANN in spectroscopy and neutron dosimetry. *J. Radio. Nucl. Chem.* 281 (3), 615–618.
- Vega-Carrillo, H., Martínez-Blanco, M., Hernandez-Davila, V., Ortiz-Rodríguez, J., 2009b. Spectra and dose woth ANN of ²⁵²Cf ²⁴¹Am.Be and ²³⁹Pu.Be. *J. Radio. Nucl. Chem.* 281 (3), 615–618.
- Vega-Carrillo, H., Ortiz-Rodríguez, J., Martínez-Blanco, M., Hernandez-Davila, V., 2010. ANN in spectrometry and neutron dosimetry. *American Institute of Physics Proccedings*, vol. 1310, pp. 12–17.
- Vega-Carrillo, H.R., Manzanares-Acuña, E., Hernandez-Davila, V.M., Barquero, R., Iñiguez, M.P., Méndez, R., Palacios, F., Arteaga, A.T., Ortíz, R.J., 2006. Neutron spectrometry using artificial neural networks. *Radiat. Prot. Meas.* 41, 425–431.
- Zhao, Wenbo, Huang, D.-S., Yunjian, G., 2002. The structure optimization of radial basis probabilistic neural networks based on genetic algorithms. In: *Proceedings of the 2002 International Joint Conference on Neural Networks*, vol. 2, pp. 1086–1091.



Contents lists available at ScienceDirect

Applied Radiation and Isotopes

journal homepage: www.elsevier.com/locate/apradiso

A neutron spectrum unfolding code based on generalized regression artificial neural networks



Ma. del Rosario Martínez-Blanco^{a,b,c,d,e}, Gerardo Ornelas-Vargas^{a,b,c,d,e},
 Celina Lizeth Castañeda-Miranda^{a,b,c,d}, Luis Octavio Solís-Sánchez^{a,b,c,d,e},
 Rodrigo Castañeda-Miranda^{a,b,c,d,e}, Héctor René Vega-Carrillo^{c,d,e,f},
 Jose M Celaya-Padilla^{a,b,d}, Idalia Garza-Veloz^{a,b,c,d,g}, Margarita Martínez-Fierro^{a,b,c,d,g},
 José Manuel Ortiz-Rodríguez^{a,b,c,d,e,*}

^a Laboratorio Nacional en Investigación, Desarrollo Tecnológico e Innovación en Sistemas Embebidos, Diseño Electrónico Avanzado y Microsistemas, Universidad Autónoma de Zacatecas, Av. Ramón López Velarde, 801, Col. Centro, 98000, Zacatecas, Mexico

^b Centro de Investigación e Innovación Tecnológica Industrial (CIITI), Universidad Autónoma de Zacatecas, Av. Ramón López Velarde, 801, Col. Centro, 98000, Zacatecas, Mexico

^c Grupo de Investigación Regional Emergente (GIRE), Universidad Autónoma de Zacatecas, Av. Ramón López Velarde, 801, Col. Centro, 98000, Zacatecas, Mexico

^d Laboratorio de Innovación y Desarrollo Tecnológico en Inteligencia Artificial (LIDTIA), Universidad Autónoma de Zacatecas, Av. Ramón López Velarde, 801, Col. Centro, 98000, Zacatecas, Mexico

^e Unidad Académica de Ingeniería Eléctrica (UAIE), Universidad Autónoma de Zacatecas, Av. Ramón López Velarde, 801, Col. Centro 98000, Zacatecas, Mexico

^f Unidad Académica de Estudios Nucleares (UAEN), Universidad Autónoma de Zacatecas, C. Cipres 10, Fracc. La Peñuela, 98068, Zacatecas, Mexico

^g Laboratorio de Medicina Molecular, Unidad Académica de Medicina Humana y Ciencias de la Salud, Universidad Autónoma de Zacatecas, Campus UAZ siglo XXI, Edificio L1, 3er Piso, Carretera Zacatecas-Guadalajara Km 6 Ejido la Escondida, 98160, Zacatecas, Mexico

H I G H L I G H T S

- Main drawback of neutron spectrometry with BPNN is network topology optimization.
- Compared to BPNN, it's usually much faster to train a (GRNN).
- GRNN are often more accurate than BPNN in the prediction. These characteristics make GRNNs to be of great interest.
- This computational code, automates the pre-processing, training and testing stages.

A R T I C L E I N F O

Article history:

Received 19 October 2015

Received in revised form

28 April 2016

Accepted 29 April 2016

Available online 30 April 2016

Keywords:

Artificial neural networks

Neutron spectrometry

Bonner spheres

Unfolding

GRNN architecture

A B S T R A C T

The most delicate part of neutron spectrometry, is the unfolding process. The derivation of the spectral information is not simple because the unknown is not given directly as a result of the measurements. Novel methods based on Artificial Neural Networks have been widely investigated. In prior works, back propagation neural networks (BPNN) have been used to solve the neutron spectrometry problem, however, some drawbacks still exist using this kind of neural nets, i.e. the optimum selection of the network topology and the long training time. Compared to BPNN, it's usually much faster to train a generalized regression neural network (GRNN). That's mainly because spread constant is the only parameter used in GRNN. Another feature is that the network will converge to a global minimum, provided that the optimal values of spread has been determined and that the dataset adequately represents the problem space. In addition, GRNN are often more accurate than BPNN in the prediction. These characteristics make GRNNs to be of great interest in the neutron spectrometry domain. This work presents a computational tool based on GRNN capable to solve the neutron spectrometry problem. This

Abbreviations: BPNN, back propagation neural networks; GRNN, generalized regression neural network; BSS, Bonner Spheres System; ANN, Artificial neural networks; PNN, Probabilistic neural networks; RBF, Radial Basis Function; IAEA, International Atomic Energy Agency; MSE, mean square error

* Corresponding author at: Laboratorio de Innovación y Desarrollo Tecnológico en Inteligencia Artificial (LIDTIA), Universidad Autónoma de Zacatecas, Av. Ramón López Velarde, 801, Col. Centro, 98000 Zacatecas, Mexico.

E-mail addresses: mrosariomb@yahoo.com.mx (Ma. del Rosario Martínez-Blanco), ornelashlls@gmail.com (G. Ornelas-Vargas), celina.castaneda@outlook.com (C.L. Castañeda-Miranda), Lsolis@ymail.com (L.O. Solís-Sánchez), rcastm@gmail.com (R. Castañeda-Miranda), fermineutron@yahoo.com (H.R. Vega-Carrillo), jose.cpadilla@gmail.com (J. Celaya-Padilla), idgarve@gmail.com (I. Garza-Veloz), margaritamf@uaz.edu.mx (M. Martínez-Fierro), morvymm@yahoo.com.mx (J.M. Ortiz-Rodríguez).

<http://dx.doi.org/10.1016/j.apradiso.2016.04.029>

0969-8043/© 2016 Elsevier Ltd. All rights reserved.

computational code, automates the pre-processing, training and testing stages using a k-fold cross validation of 3 folds, the statistical analysis and the post-processing of the information, using 7 Bonner spheres rate counts as only entrance data. The code was designed for a Bonner Spheres System based on a ${}^6\text{LiI}(\text{Eu})$ neutron detector and a response matrix expressed in 60 energy bins taken from an International Atomic Energy Agency compilation.

© 2016 Elsevier Ltd. All rights reserved.

1. Introduction

Spectrometry and dosimetry of neutron radiation is one of the most complicated tasks in radiation protection (Kardan et al., 2004a, 2004b). The monitoring of radiation exposure of neutron fields is mainly done with passive detection systems, among those systems, track detectors, film dosimeters i.e. albedo dosimeters are the most common type detector (Fehrenbacher et al., 1999). These detector use foil filters to detect said neutron fields, nevertheless, these dosimetric systems have a response that strongly depends upon neutron energy.

A special type of neutron dosimeters, commonly known as Bonner Spheres System (BSS), is also utilized as multi-element system where each element has a particular response to neutrons (Bonner, 1961; Alevra et al., 1992; Awschalom and Sanna, 1985). Usually these dosimeters have better detection efficiency in a wide energy range, allowing a better dose assessment (Fehrenbacher et al., 1999). The detection is achieved using the integral counts obtained by the active detector, said counts are weighted by factors that belong to each element (Alberts et al., 1997). The integral counts can also be used to unfold the neutron spectrum that is multiplied by neutron fluence-to-dose conversion coefficients. With the neutron spectrum information, different dose quantities can be estimated i.e. $\text{Hp}(10)$, $\text{H}^*(10)$ (International Commission on Radiation Units and Measurements, 2001).

Nevertheless, BSS have some drawbacks, the weight computation is a time consuming procedure, low resolution spectrum and the necessity of an unfolding procedure. The BSS response matrix, the count rates and the neutron spectrum are related through the discrete version of the Fredholm integro-differential equation, which is an ill-conditioned system with an infinite number of solutions. (Vega-Carrillo et al., 2002).

To unfold the neutron spectrum, several methods have been proposed such as Monte Carlo (Lindemann and Zech, 1995), regularization (Routti and Sandberg, 2001), parameterization, iterative methods (International Commission on Radiation units and Measurements, 2001) and maximum entropy (Reginatto et al., 2002) procedures. Each of them has difficulties that have motivated the development of complementary procedures (Vega-Carrillo et al., 2002; Vega-Carrillo and Iñiguez, 2002; García-Domínguez et al., 1999). Artificial neural networks (ANN) methods have been proposed (Feherembacher et al., 1999), Braga et al. proposed the "Stuttgart Neural Network Simulator", using a Back Propagation Neuronal Network (BPNN) to unfold the neutron spectra, the methodology was tested in twenty-two spectra with a reported error of 0.0014, however the methodology required 3×10^5 iterations to achieve said performance. (Braga and Dias, 2002; Kardan et al., 2003). Recently, Suman et al. proposed a new approach using the Monte Carlo methodology to unfold the spectra and as a fitness function, then using a genetic algorithm several Monte Carlo solutions were gathered and merged into the final solution to unveil the spectra, a set of 37 spectra were used to test the system, a reported a 2.32×10^{-3} Chi-square was obtained, after up to 1000 generations (Suman et al., 2014). However, the application of ANN to unfold actual neutron spectra still has some problems. Significant work is still to be done in order to assess the feasibility of

the ANN for the spectrum unfolding problem (Braga and Dias, 2002).

ANN are a large structured system of equations (Haykin, 1999). These systems have many degrees of freedom and are able to adapt to the task they are supposed to do (Galushkin, 2007; Apolloni et al., 2009). Generally, the most common type of ANN, falls into two different types: Back Propagation Neuronal Networks (Graupe, 2007; Mohan et al., 1997; Jain et al., 1996) and probabilistic neural networks (PNN) (Chtioui et al., 1997; Huang and Zhao, 2005; Mao et al., 2000; Huang, 1999). BPNN use equations that are connected using the weight factors (Arbib, 2003; Hammer and Vilmann, 2003). The selection of the weighting factors makes these neural networks so powerful. On the other hand, PNN uses a statistical approach to select the equations within the structure and do not weight these functions (Mao et al., 2000; Huang, 1999; Specht, 1998).

Previous research of ANN in neutron spectrum unfolding indicate that BPNN perform well (Braga and Dias, 2002; Kardan et al., 2004a, 2004b; Fehrenbacher et al., 1999; Hernandez-Davila et al., 2005; Vega-Carrillo et al., 2009). However, BPNN have serious drawbacks in neutron spectrometry; the proper determination of the network architecture, the long training periods, another drawback is the lack of available neutron spectra data to train and test the networks, said BPNN networks usually require huge data to train (Ortiz-Rodríguez et al., 2013). Even that Generalized Regression Neural Network (GRNN) and BPNN are complementary versions of the same ANN architecture, GRNN is usually much faster to train (Chtioui et al., 1997; Mao et al., 2000).

The GRNN may converge even with a fraction of the training samples as a BPNN typically needs (Mao et al., 2000) (Huang, 1999; Specht, 1998). Therefore, the use of a GRNN is especially advantageous due to the ability to converge with only few training samples available. The additional knowledge needed to get the fit in a satisfying way is relatively small and can be done without additional input by the user. GRNN only require the spread constant parameter, opposite to BPNN in which, before the training stage, it is necessary to determine many learning and architectural parameters of the network (Ortiz-Rodríguez et al., 2013).

A GRNN is a feed forward neural network based on non-linear regression theory consisting of four layers: the input layer, the pattern layer, the summation layer and the output layer. Said GRNN function as an approximation for complex tasks such as system modeling and prediction. The neurons in the first three layers are fully connected, each output neuron of said layer is connected only to some processing units in the summation layer, a schematic of a GRNN is shown in Fig. 1.

As can be seen from Fig. 1, the first layer is the input layer and is fully connected to the pattern layer. The second layer is the pattern layer and has one neuron for each input pattern. The neuron stores the values of the predictor variables along with the target value.

The function of the pattern layers of the GRNN is a Radial Basis Function (RBF) (Specht, 1998; Specht and Shapiro, 1991), typically a Gaussian kernel function, as can be seen in Fig. 2, the activation of pattern units characterizes the distance of the center of a RBF to produce; localized, bounded, and rapidly symmetric activations, those activations rapidly decrease with the distance from the




Fig. 1. General structure of GRNN.

function's center. The RBF is named because the radius distance is the argument to the function, as seen in Fig. 2.

The width of a RBF of the pattern units, also known as the spread constant σ , is an important parameter allowing the user to influence the generalization capabilities of the GRNN. Said spread parameter σ , determines the spread of the function RBF; that is, how quickly the function declines as the distance increased from the point of the Radial Basis Function, therefore, with larger sigma values, distant points have a greater influence. In general, larger values of the spread constant results in a smoother interpolation of the output vectors values among the values corresponding to the centers of RBF of the individual pattern units.

The summation layer has two different types of processing units: the summation units and the single division unit. The number of the summation units is always the same as the number of the GRNN output units. The summation unit adds up the weight values coming from each of the pattern neurons. The division unit only sums the weighted activations of the pattern units without using any activation function.

Another useful characteristic of GRNN, which makes it faster in the training stage, is that there is only the linear output layer beyond the first hidden layer; this guarantees that the network will converge to a global minimum, provided that the optimal value of spread has been determined and that the dataset adequately represents the problem space. In addition, for some specific problems, GRNN may be more accurate than BPNN in the prediction (Ma. del Rosario Martinez-Blanco et al., 2016). These characteristics makes GRNN good candidates in the neutron spectrometry research area. However, since this is an emergent research field, one drawback is the lack of scientific knowledge and technological tools to train and test GRNN in the neutron spectrometry field.

The aim of this work is to train a GRNN capable to solve with high efficiency the neutron spectrum unfolding problem. To achieve the before mentioned, a neutron spectrum unfolding computational tool based on a GRNN methodology was designed. This computer code was developed under the Matlab




Fig. 2. Radial Basis Function (RBF).

programming environment (MATLAB and Statistics Toolbox Release, 2012), automates the stages of: pre-processing the information used to train and test the network, the selection of the spread constant, the training and testing stages of the network, the analysis of the performance of the trained network and the storing of information produced before, during and after training and testing stages for further analysis. The automated algorithm saves a lot of time, and potentially human induced errors.

In order to assess the performance of the proposed methodology, a 3k-fold cross validation strategy was used, two thirds of the data were used to train the GRNN, and the rest of the data was used to assess the performance. To determine the optimum spread constant value, around 2000 neural networks were trained in 157 s average. The final GRNN was trained and tested in 0.058 s average using the calculated optimum spread constant by each fold. After training, the performance of the network was analyzed by comparing the output of the trained network with the expected value. In this work, the best and the worst cases are shown by each fold. Results of the trained GRNN for neutron spectrometry shows high efficiency and generalization capability.

2. Materials and methods

As previously mentioned, GRNN applied in neutron spectrometry is an emergent research field, in which one drawback is the lack of scientific knowledge and technological tools to train, test and to evaluate the performance of the knowledge acquired by the networks trained. In this work, a GRNN was trained in order to solve the neutron spectrometry problem by using a customized designed tool.

In this work, a neutron spectrum unfolding computer tool based on neural nets technology was designed to train a GRNN capable to solve the neutron spectrum unfolding problem with high performance and generalization capabilities. The code automates the preprocessing, training, testing, validation and post processing stages of the information generated by the GRNN. The code is capable to train, to test and validate GRNN. After training and testing the neural net, the code analyzes, graph and stores the results obtained.

In order to train GRNNs, the code uses 251 neutron spectra extracted by the International Atomic Energy Agency (IAEA) compilation (IAEA, 2001). The IAEA's compendium contains a large collection of detector responses and spectra. The report aims to provide specific technical information that could be used by radiation protection specialists for proper selection of dosimeters

and survey instruments, and for interpretation of data obtained with these detectors.

At this stage of development, the customized technological tool designed to train GRNNs for neutron spectrometry uses 251 neutron spectra and three response matrix from IAEA’s compilation. The designed technological tool automates the following activities:

- Read the neutron spectra data set coming from the IAEA's compendium, which are expressed in 60 energy bins.
- Read a response matrix used to train the neural network.
- Because the neutron spectra coming from IAEA's compendium are expressed in lethargy units, the code converts these spectra in energy units.
- The neutrons expressed in energy units are multiplied by the selected response matrix in order to calculate the count rates.
- To train the GRNN, the code uses the 251 calculated count rates as entrance data and their corresponding neutron spectra expressed in energy units as the output data, Fig. 3 shows an example of neutron spectra.
- A *k-fold* cross validation of 3 folds is used to measure the performance of the methodology, two thirds of the data are used for the train stage, and the remaining is used in the test stage at each fold. Fig. 4 shows an example of the neutron spectra data set used on testing stage, compared with target spectra.
- Using the before calculated information, the following stage was to determine the spread constant value. To calculate this value, the computer tool trains several neural networks varying this value from 0 in increments of 0.01 through 2 and compare the mean square error (mse) which is used to determine the performance of the network. The minimum value obtained is selected as the spread constant value. 2000 GRNN were trained to determine in 157 s average, an optimum value equal to 0.2711 was selected, Fig. 5 shows the optimum spread constant value.
- To assess the performance, in each fold: Using the calculated spread constant value, a final GRNN was trained and tested in 0.058 s average in only one epoch. At testing stage the code compares and analyze the output of the trained neural network with the expected spectrum, showed in Fig. 4. At testing stage 82 neutron spectrum, randomly selected, were used to analyze the performance of the trained network, performing chi square and correlation tests. In this work, the best and the worst cases are shown from Figs. 6 through 9.

At testing stage, the 82 counts rates randomly selected in the preprocessing stage, are used to test the performance and generalization capabilities of the trained network, no target output is proportionated to the network. The designed code analyzes and




Fig. 4. Neutron spectra data set used on testing stage, compared with target spectra.




Fig. 5. Optimum spread constant value, sigma, determination.

compare the output of the network with the neutron spectrum expected as is shown in figures 6–9.

3. Results

Fig. 6, shows the best spectrum observed at the testing stage in all the folds, compared with the expected output. The values showed in Figures 6 through 9 were calculated and graphed with the customized technological computer code.

As can be seen from Fig. 6, with the proper selection of the spread constant value, the trained GRNN calculated the 60 energy bins values of the spectrum, said values are around the target value (the spectrum from the IAEA’s compendium). Opposite to BPNN, non-negative values and oscillations around the target value are generated when GRNN are used.

As can be appreciated in Fig. 6, the performance of the trained network was $2E-4$. The chi-square test was 0.33636, near to the optimum value and far from the statistical margin. The correlation test was 0.99856, meaning that the GRNN calculated value and the expected spectra are very similar, therefore, the network performance is high.

Fig. 7 shows the chi-square and the correlation test of the best spectrum at the testing stage. From this figure it can be seen that the predicted and expected values, are very similar, for this experiment, a chi-square of 0.33636 was obtaining in the test stage

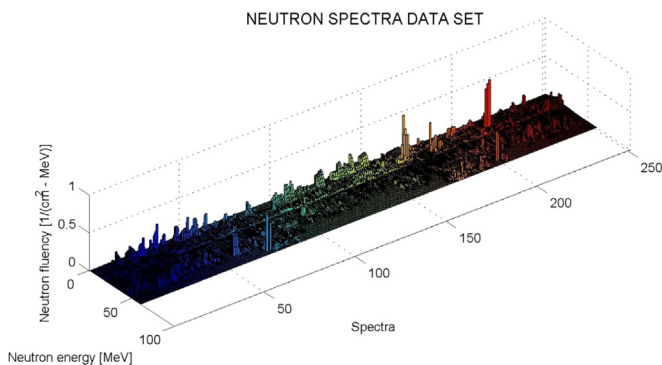


Fig. 3. Neutron spectra data set, expressed in energy units, used to train the GRNN.




Fig. 6. Best spectrum obtained at the testing stage compared with target spectrum.

with a correlation of 0.99856, the calculated and target spectrum is very similar, the trained GRNN exhibited a high performance and generalization capabilities.

Fig. 8 shows the worst spectrum observed at the testing stage. From this figure it can be seen that the predicted energy bins spectrum are around of the target value. The chi square and correlation tests, 0.15759 and 1.0072 were obtained respectively.

As can be seen from Figs. 8 and 9, the values for the worst GRNN are less close from expected values, however, even on the worst case the values still predict the expected value in a reasonable way, therefore, demonstrating the power of a GRNN for the solution of the neutron spectrum unfolding problem, using only a limited amount of information extracted from the IAEA's compendium.

Table 1, shows the complete set of values gathered during the cross validation experiment, all the values presented were obtained during the test set, an average correlation of 0.99608 was obtained for the three best GRNN's with an average χ^2 of 0.37382 for said networks. The worst correlation and χ^2 values are also shown, an average correlation of 0.30043 was obtained for the three worst GRNN's, an average χ^2 of 0.97455 was achieved for said networks.




Fig. 7. Best correlation test obtained at the testing stage.

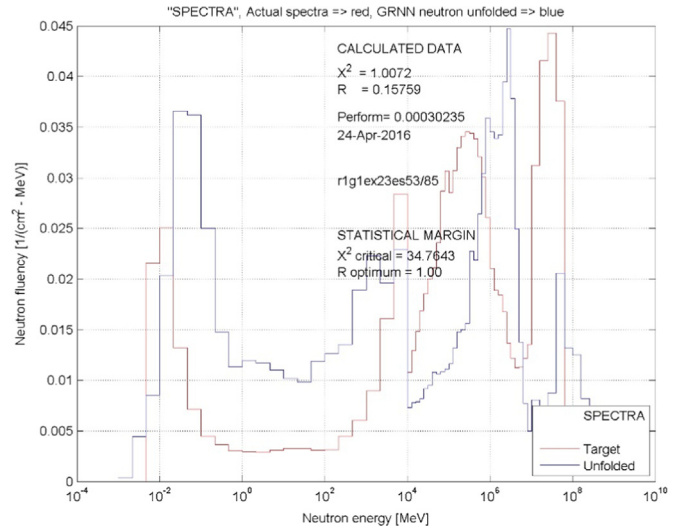


Fig. 8. Worst spectrum obtained at the testing stage compared with target spectrum.




Fig. 9. Worst correlation test obtained at the testing stage.

Table 1

Performance of the methodology using 3 K-fold cross validation.

Fold	Best R	χ^2	Worst R	χ^2
1	0.99158	0.13164	0.28016	1.18
2	0.99811	0.65348	0.15759	1.0072
3	0.99856	0.33636	0.46355	0.73647
Average	0.99608	0.37382	0.30043	0.97455

Values for the best and worst GRNN by each fold are presented.

4. Discussion

ANN technology is widely recognized as a powerful modeling tool. An ANN is a massively parallel distributed processor, that through a learning process acquires experiential knowledge, making available for use. In general, an ANN is a set of input nodes that links directly to a series of output nodes or indirectly through one or more hidden layers. The use of an ANN requires the training of the network and the testing of the trained network. During the

training, a set of synaptic weights is obtained, where the knowledge is stored.

GRNN is a special case of PNN. Compared with its competitor, i.e. BPNN, GRNN has several advantages: First of all, the structure of a GRNN is relatively simple and static with 2 layers, namely pattern and summation layers. Once the input goes through each unit in the pattern layer, the relationship between the input and the response would be “memorized” and stored in the unit. As a result, the number of units in the pattern layer is equal to the number of observations in the training sample. This type of network, is able to learn from the training data by “1-pass” training, this training represents a fraction of the time it takes to train BPNN. The spread constant value, is the only free parameter in the network. Unlike standard BPNN, GRNN estimation is always able to converge to a global solution and won't be trapped by a local minimum.

The use of GRNN to unfold the neutron spectra from the count rates measured with the BSS is a promising alternative procedure, which has been applied with success in this work. However, one of the main drawbacks was the lack of scientific and technological tools based on this technology. Therefore, a scientific computational tool was designed to train, to test, to analyze and to validate GRNN in this research domain.

5. Conclusions

An ANN simulates a highly interconnected parallel computational structure, with many individual processing elements or neurons. It learns through an iterative process of adjustments to its synaptic weights and thresholds. A defined set of rules for the solution of a learning problem is the learning algorithm.

GRNN is one of the simplest neural network, in term of network architecture and learning algorithm. The training pattern can be considered as the center of Gaussian function and the target output could be considered as a multiplier of the probability density function. Another advantage is that the learning is instantaneous, which mean require no time for training. In this work, around 2000 neural networks were trained in 154 s average to determine the best performing network. Each network was trained in 0.058 s average.

The purpose of this work was to apply GRNN to predict the neutron spectrum using the count rates data from a BSS. Two hundred and fifty-one different types of neutron spectra, a limited amount of IAEA's information were used as training dataset. A *k-fold* cross validation of 3 folds was used to measure the performance of the methodology. a customized computer tool was designed in Matlab to train and test a GRNN for the neutron spectrum unfolding, said tool, automates the preprocessing and the post processing information in the training and testing stages.

In the GRNN testing stage 82 spectra were predicted using the trained GRNN at each fold. Comparison with the standard spectra shows that the trained GRNN has high performance and generalization capabilities, indicating that ANN technology could be used as a promising alternative with high accuracy in neutron spectrum unfolding techniques.

Acknowledgement

This work was partially supported by Fondo Sectorial de Investigación para la Educación under contract 241771.

This work was partially supported by Fondos Mixtos SEP-CONACYT under contract ZAC-C03-2015-26357-4.

This work was partially supported by PROSOFT under contract 201513723.

The first author want to thank the Doctorate scholarship, with scholarship holder number 23386, received by Fondo Sectorial de Investigación para la Educación under contract 241771.

The second author want to thank the Doctorate scholarship, received by Fondos Mixtos SEP-CONACYT under contract ZAC-C03-2015-26357-4.

References

- Alberts, W., Dorschel, B., Siebert, B., 1997. Methodological studies on the optimization of multi-element dosimeters in neutron fields. *Radiat. Prot. Dosim.* 70, 117–120.
- Alevra, A., et al., 1992. Experimental determination of the response of four Bonner sphere sets to monoenergetic neutrons (II). *Radiat. Prot.* 40 (2), 91–102.
- Apolloni, B., Bassis, S., Marinaro, M., 2009. *New Directions in Neural Networks*. s.l.: IOS Press, Netherlands.
- Arbib, M., 2003. *Brain Theory and Neural Networks*. s.l.:The Mit Press, London, England.
- Awschalom, M., Sanna, R., 1985. Applications of Bonner sphere detectors in neutron field dosimetry. *Rad. Prot. Dosim.* 10 (1–4), 89–101.
- Bonner, T., 1961. Measurements of neutron spectra from fission. *Nucl. Phys.* 23, 116–121.
- Braga, C., Dias, M., 2002. Application of neural networks for unfolding neutron spectra measured by means of Bonner spheres. *Nucl. Instrum. Methods Phys. Res. Sect. A: Accel., Spectrometers, Detect. Assoc. Equip.* 476 (1–2), 252–255.
- Braga, C., Diaz, M., 2002. Application of neural networks for unfolding neutrons spectra measured by means of Bonner spheres. *Nucl. Instrum. Methods Phys. Res.* 476, 252–255.
- Chtioui, Y., Bertrand, D., Devaux, M., Barba, D., 1997. Comparison of multilayer perceptron and probabilistic neural networks in artificial vision. Application to the discrimination of seeds. *J. Chemom.* 11 (2), 111–129.
- del Rosario Martínez-Blanco, M., Ornelas-Vargas, G., Solís-Sánchez, L.O., Castañeda-Miranada, R., Vega-Carrillo, H.R., Celaya-Padilla, J.M., Ortiz-Rodríguez, J.M., 2016. A comparison of back propagation and generalized regression neural networks performance in neutron spectrometry. *Appl. Radiat. Isot.*
- Fehrenbacher, G., et al., 1999. Proposal of a new method for neutron dosimetry based on spectral information obtained application of artificial neural networks. *Radiat. Prot. Dosim.* 83 (4), 293–301.
- Galushkin, Alexander I., 2007. *Neural Networks Theory*. Springer, Singapore.
- García-Domínguez, E., Miramontes-de León, G., Vega-Carrillo, H., McBride, L., 1999. Noniterative unfolding algorithm for neutron spectrum measurements with Bonner spheres. *IEEE Trans. Nuclear Sci.* 46, 28–35.
- Graupe, D., 2007. *Principles of Artificial Neural Networks*. s.l. World Scientific.
- Hammer, B., Vilmann, T., 2003. *Mathematical aspects of neural networks*. ESANN'2003 proceedings - European Symposium on Artificial Neural Networks, pp. 59–72.
- Haykin, S., 1999. *Neural Networks: A Comprehensive Foundation*. Prentice Hall., New Jersey, USA.
- Hernandez-Davila, V., et al., 2005. Neutron spectra unfolding with artificial neural networks. *Encuentro Investig. Ing. Electr. (ENINVIE 2005)*, 132–139.
- Huang, D., 1999. Radial basis probabilistic neural networks: model and application. *Int. J. Pattern Recognit. Artif. Intell.* 13 (7), 1083–1101.
- Huang, D., Zhao, W., 2005. Determining the centers of radial basis probabilistic neural networks by recursive orthogonal least square algorithms. *Appl. Math. Comput.* 162 (1), 461–473.
- IEAE, 2001. *Compendium of neutron spectra and detector responses for radiation protection purposes*. s.l.:s.n.
- International Commission on Radiation units and Measurements, 2001. *Methods for routine monitoring Report 66*. J. ICRU 1, 35–52.
- International Commission on Radiation units and Measurements, 2001. *Neutron field characterization Report 66*. J. ICRU 1, 27–33.
- Jain, A.K., Mao, J., Mohiuddin, K.M., 1996. Artificial neural networks: a tutorial. *IEEE Comput.* 29 (3), 31–44.
- Kardan, M., Setayeshi, S., Koohi-Fayegh, R., Ghiassi-Nejad, M., 2003. Neutron spectra unfolding in Bonner spheres spectrometry using neural networks. *Radiat. Prot. Dosim.* 104, 27–30.
- Kardan, M., Koohi-Fayegh, R., Setayeshi, S., Ghiassi-Nejad, M., 2004a. Fast neutron spectra determination by threshold activation detectors using neural networks. *Radiat. Meas.* 38, 185–191.
- Kardan, M., Koohi-Fayegh, R., Setayeshi, S., Ghiassi-Nejad, M., 2004b. Neutron spectra unfolding in Bonner spheres spectrometry using neural networks. *Radiat. Prot. Dosim.* 104 (1), 27–30.
- Lindemann, L., Zech, G., 1995. Unfolding by weighting Monte Carlo events. *Nucl. Instrum. Methods Phys. Res.* 354, 516–521.
- Mao, K., Tan, K., Ser, W., 2000. Probabilistic neural-network structure determination for pattern classification. *IEEE Trans. Neural Netw.* 11 (4), 1009–1016.
- MATLAB and Statistics Toolbox Release, 2012, The MathWorks, Inc., Natick, Massachusetts, United States.
- Mohan, C.K., Mehrotra, K., Ranka, S., 1997. *Elements of artificial Neural Networks*. s.l.: MIT Press.
- Ortiz-Rodríguez, J., Martínez-Blanco, M., Cervantes-Viramontes, J., Vega-Carrillo, H., 2013. Robust design of artificial neural networks methodology in neutron

- spectrometry. In: Suzuki, K. (Ed.), *Artificial Neural Networks - Architectures and Applications*. . s.l.:InTech, pp. 83–111.
- Reginatto, M., Goldhagen, P., Neumann, S., 2002. Spectrum unfolding sensitivity analysis and propagation on uncertainties with the maximum entropy deconvolution code MAXED. *Nucl. Instrum. Methods Phys. Res.* 476, 242–246.
- Routti, J., Sandberg, J., 2001. General purpose unfolding program LOUHI78 with linear and non-linear regularization. *J. ICRU Volume 1*, 27–33, Report 66.
- Specht, D., 1998. Probabilistic neural networks for classification, mapping, or associative memory. *IEEE International Conference on Neural Networks*, Volume 1, pp. 525–532.
- Specht, D., Shapiro, P., 1991. Generalization accuracy of probabilistic neural networks compared with backpropagation networks. *IJCNN-91-Seattle International Joint conference on Neural Networks*, Volume 1, pp. 887–892.
- Suman, V., Sarkar, P.K., 2014. Neutron spectrum unfolding using genetic algorithm in a Monte Carlo simulation. *Nucl. Instrum. Methods Phys. Res. A* 737 (2014), 76–86.
- Vega-Carrillo, H., Iñiguez, M., 2002. Catalogue to select the initial guess spectrum during unfolding. *Nucl. Instrum. Methods Phys. Res.* 1, 270–272.
- Vega-Carrillo, H., Manzanares-Acuña, E., Becerra-Ferreiro, A., Carrillo-Núñez, A., 2002. Neutron and gamma-ray spectra of ²³⁹PuBe and ²⁴¹AmBe. *Appl. Radiat. Isot.* Volume 57, 167–170.
- Vega-Carrillo, H., Martínez-Blanco, M., Hernández-Dávila, V., Ortiz-Rodríguez, J., 2009. Spectra and dose with ANN of ²⁵²Cf, ²⁴¹AmBe and ²³⁹PuBe. *Radio. Nucl. Chem.* 281 (3), 615–618.

Further reading

- International Atomic Energy Agency, 1990. Compendium of neutron spectra and detector responses for radiation protection purposes. *Technical Reports Series no. 318*.
- Briesmeister J., 2000. MCNP TM A general Monte Carlo N-particle transport code, Los Alamos National Laboratory LA-13709-M: S.n.
- Féraud, R., Clérot, F., 2002. A methodology to explain neural networks classification. *Neural Netw.* 15, 237–246.
- Freeman, D., Edwards, D., Bolon, A., 1999. Genetic algorithms-a nes technique for solving the neutron spectrum unfolding problem. *Nucl. Instrum. Methods Phys. Res.* 425, 549–576.
- International Atomic Energy Agency, 2001. Compendium of neutron spectra and detector responses for radiation protection purposes: Supplement to Technical Reports Series no. 318. *IEAE Technical Report Series*, Volume 403.
- Mukherjee, B., 2002. A high-resolution neutron spectra unfolding method using the genetic algorithms technique. *Nucl. Instrum. Methods Phys. Res.* 476, 247–251.
- Specht, D., Romsdahl, H., 1994. Experience with adaptive probabilistic neural network and adaptive general regression neural networks. *IEEE International Conference on Neural Networks - IEEE World Congress on Computational Intelligence*, Volume 2, pp. 1203–1208.

A Study Using the Robust Design of Artificial Neural Networks Methodology in Neutron Spectrometry

Ortiz-Rodriguez J.M., Martinez-Blanco M.R., Ornelas-Vargas G., Guerrero-Ozuna H.A., Mendoza-Hasso J.H., Solis-Sanchez L.O. and Castañeda-Miranda R.

Laboratorio de Innovacion y Desarrollo Tecnologico en Inteligencia Artificial, Unidad Academica de Ingenieria Electrica
Centro de Investigacion e Innovacion Tecnologica Industrial, Universidad Autonoma de Zacatecas
Zacatecas, Mexico
morvymm@yahoo.com.mx

Abstract— In this work, a systematical and methodological ANN optimization process known as robust design of artificial neural networks methodology, based on Taguchi method and Design of Experiments methodology, was applied to the design, training and testing of feed forward artificial neural networks trained with back-propagation training algorithm applied in the neutron spectrometry research area. The methodology was utilized to study the neutron spectrum unfolding problem by using a data set composed by 187 neutron spectra compiled by the International Atomic Energy Agency. In order to study the behavior of the designed neural networks topologies, four cases of grouping the neutron spectra were considered. In the first case 17 neutron spectra subsets were tested. In the second one 6 subsets. In the third case a data set with 53 neutron spectra and finally, in the fourth case, a data set with 187 neutron spectra was tested. For all the subsets, the robust design of artificial neural networks methodology was carried out. Around 1000 different neural network topologies were trained and tested, 36 net topologies for each subset. After all the network topologies were trained and tested, it was observed that the near optimum neural network topology which produced the best results was the fourth case, with the following topology: 7 neurons in the input layer, corresponding to the Bonner spheres readings; 14 neurons in a hidden layer and 31 neurons in the output layer corresponding to the 31 energy bins in which the spectrum is expressed, a learning rate and momentum equal to 0.1. The results obtained reveal that the robust design methodology offer potential benefits in the evaluation of the behavior of the net as well as the ability to examine the interaction of the weights and neurons inside the same one.

Keywords—Artificial neural networks; Optimization; neutron spectrometry; Bonner spheres.

I. INTRODUCTION

Spectrometry measurements and dose calculus have played a vital role in helping to understand the nature and origins of the ionizing radiation [1]. The measurements and calculations of neutron fluence spectra are a key factor in radiation protection dosimetry of neutrons, mainly because there are different neutron sources that can impact the working conditions [2, 3].

Although there is a wide range of different devices used for neutron spectrometry, the majority of the instruments can be grouped together into a small number of broad categories, each

one based on a common underlying technique such as time-of-flight, nuclear reaction methods, nuclear recoil methods and the use of integral detectors [3]. Using integral detectors, neutron dosimeters are utilized as multi-element systems, as in the case of the Bonner Spheres Spectrometer (BSS) system, where each element has a particular response to neutrons [4]. These dosimeters usually have better detection efficiency in a wider energy range allowing a better dose assessment.

Neutron spectrum unfolding using the count rates of a BSS system is an ill-conditioned problem having an infinite number of solutions, therefore, the determination of neutron spectrum is not a trivial task because the unknown is not given directly as a result of the BSS measurements [5]. The relationship between the BSS count rates, C , the BSS response, $R_{i,j}$, and the neutron spectrum Φ_j , is given by the discrete version of Fredholm equation of first kind given in eq. 1, where j is the amount of spheres utilized and i is the amount of energy groups used to define the neutron spectrum .

$$C_j = \sum_{i=1}^N R_{i,j} \Phi_j \quad (1)$$

To unfold the neutron spectra, Φ_j , several methods like Monte Carlo [6], parameterization [7], regularization and iterative procedures [8] have been utilized. Each of them has some drawbacks that have motivated to researchers to propose new and complementary approaches [9, 10]. Some researchers have proposed the use of Artificial Neural Networks (ANN) technology to unfold the neutron spectra from Bonner Spheres Spectrometers (BSS) system [11 - 13].

Artificial Intelligence (AI), is a branch of study which enhances the capability of computers by giving them human like intelligence [14]. Artificial neural networks (ANNs) have been studied for many years in the hope of achieving human-like performance [15]. ANNs represents an area of AI and are computational paradigms based on mathematical models that unlike traditional computing have a structure and operation that resembles the brain [16].

Over the last few years there has been a resurgence of interest in artificial neural networks as researchers from diverse backgrounds have produced a firm theoretical foundation and demonstrated numerous applications of this research field of

study and numerous advances have been made in developing intelligent systems [17].

Until now a large variety of neural networks architectures have been developed and they have gained wide-spread popularity over the last few decade. Their application is considered as a substitute for many classical techniques that have been used for years [18]. Researchers for many disciplines are designing ANNs for solving a wide variety of problems such as digital signal processing, recognition of patterns, speech recognition, control and optimization, prediction, adaptive interfaces for man/machine systems and recently in the neutron spectrometry research field [11 - 13].

Although a lot of research of ANN is been concentrated in developing ANN's models and training algorithms to improve the accuracy and convergence of the models, there still a conventional problem in the ANN design, determining a suitable set of structural and learning parameters values for an ANN still remains a difficult task, researchers have to choose the architecture and determine many of the parameters in a selected ANN [19].

It is not easy for a user to choose a suitable network even if he is an experienced designer. As is shown in fig. 1, the current practice of selecting the levels for neural networks design parameters is based on the trial-and-error technique which is similar to the one-factor-at-a-time experiment. If changing the level of one particular design parameter has no effect on the performance of the neural network then a different design parameter is varied and the experiment is repeated in a series approach. This procedure consuming much time and does not systematically target a near optimal solution, which may lead to a poor overall neural network design.




Fig. 1. Series trial-and-error approach of ANN design

By using the trial-and-error technique the observed responses are examined at each stage to determine the best level of each design parameter. This method cannot identify interactions between the parameters and may lead to a poor overall neural network design. The current ANNs design methodologies, serial and trial error, do not propose systematic methodologies for the identification of the best values. The process is treated very much as serial, trial and error exercise, consuming much time and does not systematically target a near optimum solution. Therefore, there must be an easier and more efficient way to overcome this disadvantage.

In contrast to the trial-and-error technique, the robust design of artificial neural networks methodology (RDANNM), showed in fig. 2, based on the Taguchi method and Design of Experiments methodology (DoE) is a very powerful method based on the parallel process where all the experiments are planned a priori and the results are analyzed after all the experiments are completed [20].

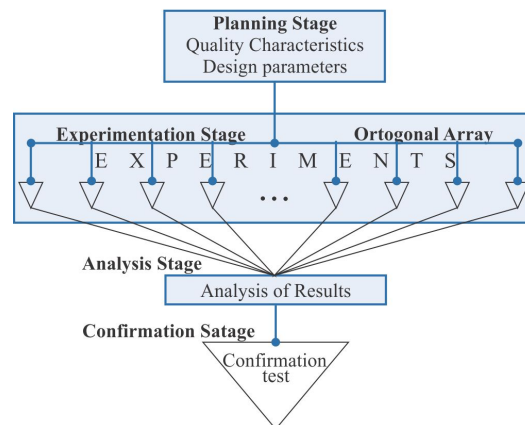


Fig. 2. RDANNM ANN design approach of ANN design

In order to design ANN of high performance and generalization capability, the parameters related to the training (learning rate, momentum) as well as the network structure (number of hidden layers and neurons) must be considered simultaneously, together with their interaction effects. In addition, there exist nuisance parameters in training. They include initial set of weights, division of the whole data set into the training and testing data sets, sizes of the training and testing data sets. It is also desired that the performance of a feed-forward ANN trained with back-propagation training algorithm be robust to these nuisance parameters [21].

RDANNM is one of the appropriate methods for achieving this goal. The fundamental concept rests on the importance of economically achieve high quality, low variability and consistency of functional performance. The methodology is based heavily on statistical methods, and concentrates on minimizing the variation around the target performance. The end result is a "robust" design which is lest sensitive to noise factors. In this, the reduction on variation is obtained without removing its causes.

In this work, the RDANNM was used to design an ANN capable to solve the neutron spectrometry problem, using the count rates measured with a BSS as entrance data. In order to study the behavior of the designed neural networks topologies, four cases of grouping the neutron spectra were considered: case I - 17 neutron spectra subsets, case II - 6 neutron spectra subsets, Case III - a data set with 53 neutron spectra and Case IV - a data set with 187 neutron spectra. Around 1000 different network topologies were trained and tested, 36 net topologies for each subset. The results obtained reveal that the robust design methodology offer potential benefits in the evaluation of the behavior of the net as well as the ability to examine the interaction of the weights and neurons inside the same one.

II. MATERIALS AND METHODS

As can be seen from fig. 2, RDANNM has four main stages named planning, experimentation, analysis and confirmation. Identifying the performance characteristics is the first step at planning stage. Since the objective of the experiments is to find a robust ANN under various noise conditions to maximize its performance and generalization capability, prediction or classification errors between the target and the ANN output values of the testing data are used as the performance characteristic, i.e., the mean square error (mse).

The second step in this methodology is to identify the design and noise variables and their levels. Among the various parameters that affect the ANN performance, four design variables are selected. That is, for the structure of the ANN, the number of neurons in each of the first and second hidden layers as well as the learning rate and momentum are selected as learning parameters while the noise variables included in the experiment are the initial set of weights which are usually randomly selected. In addition, how much of the whole data should be allocated to the training and testing data sets. Once this is determined, which data of the whole data set to include in the training or testing data set.

For the experimental design Orthogonal Arrays (OAs) are used, which are denoted by $L_r(s^c)$ where r is the number of rows, c is the number of columns, and s is the number of levels in each column. A design variable is assigned to a column of the design OA. Similarly a noise variable is assigned to a column of the noise OA. At each combination of design and noise conditions the corresponding ANN is trained and tested using a customized computational tool developed to this purpose. At experimental stage, a crossed OA $L_9(3^4)$, $L_4(3^2)$ was used.

At analysis stage, the signal-to-noise (S/N) ratio is measured conducting confirmation experiments at the optimal condition, comparing the S/N ratios for closeness and then, the optimal levels of the ANN are determined. Finally, at confirmation stage, the confirmation of the optimal design conditions is realized.

III. RESULTS

The results obtained after applying RDANNM in the four cases studied are summarized in table 1. This table shows the performance (mse) reached for each neural net and the Chi square statistical test obtained for the optimal ANNs. Around 1000 different ANN topologies were trained and tested, in order to answer several design and construction issues and to determine the best ANN topology.

After applying the RDANNM one interesting observation was that the optimum network architecture in all the subsets of the cases I, II and III was the same: $A = 14$, $B = 0$, $C = 0.001$, $D = 0.1$; In contrast, the ANN topology for the case IV was: $A = 14$, $B = 0$, $C = 0.1$, $D = 0.1$. This reveals that an optimized neural network applied in neutron spectrometry field can be solved with one hidden layer with around 15 neurons.

As can be seen from table 1, in case I, the network performance had very high values, compared with the established value for the objective function ($1E-4$). The ANN learning and generalization were very poor because the amount of data used in ANN training stage. In addition, Chi square tests in most cases were above limit of the level of trust (18.5 for a confidence level of 95% for 30 degrees of freedom). Can be concluded that this way to order the neutron spectra in 17 subsets is faulty since the ANNs designed have a very poor learning capability and because the little information used in each subset at training stage, the ANN is not capable to generalize because the neutron spectra subsets have not enough information.

Unlike case I, in case II, in each subset was included a bigger number of neutron spectra. This in order to generate a biggest learning and generalization capacity in the ANN designed. When making the Chi square test to the 6 cases of grouping of spectra, most of the values were below the critical value (18.5). The correlation statistical test demonstrated that the reconstructed spectra were better than those obtained in case I, however, for this case the unfolded neutrons neither were satisfactory and this way to order the neutron spectra is faulty too.

From cases I and II was observed that the neutron spectra information for each subset was not enough to get a suitable ANN learning and generalization capability. For this reason, a data set with 53 neutron spectra was created, ordering the information according neutron spectra shape, to observe the ANNs behavior as shown in table 2.

This way to order the neutron spectra information is better if compared with cases I and II because the objective function, (mse), established at planning stage is reached most of times. However, in some of the 36 responses the mse is not reached as shows table 2. This indicates that the ANN designed has better learning and generalization capability, mainly because the amount of information applied to the ANN in the training stage. The anterior results demonstrate that in case III, the reconstructed spectra are better than cases I and II, however, for this case the unfolded neutrons neither are satisfactory and this way to order the neutron spectra is still faulty.

Observing that the quantity and quality of information introduced to the ANN is of great importance, it was created a fourth data set with 187 neutron spectra. It was expected that the ANN being designed had a great learning capability and generalization power. Table 3 shows the results obtained where can be seen that the network performance is better if compared with cases I, II and III and in consequence the reconstructed spectra will be better too. The responses obtained in the OA indicate that this way to order the neutron spectra information is the best from the four cases considered, producing the best ANN architecture. From table 3 can be observed that the objective function is reached in all the 36 cases of the OA.

Table I. Results obtained after training the four cases of grouping spectra using RDANNM

QUANTITY	GROUPS		PERFORMANCE	CHI SQUARE (χ^2)	
	SUBGROUP NO.	SPECTRA		MAX	MIN
Case I: 17 subsets	6	This subset was not used, because the high energy			
	13	4	4.96122E-01	6200.10	2102.20000
	4	10	2.48376E-02	1309.60	3.54960
	17	5	2.30758E-02	124.13	6.30570
	15	9	1.32717E-02	5833.10	8.52910
	8	10	8.86023E-03	121.58	0.31706
	14	13	7.84309E-03	2159.90	0.43618
	2	10	6.24649E-03	71.28	0.47689
	5	12	5.60118E-03	5.19	0.29301
	3	14	3.10347E-03	7.72	0.12835
	11	13	3.00732E-03	2008.80	0.33484
	1	15	2.55145E-03	194850.00	0.14960
	12	18	1.71680E-03	3635.90	1.95550
	9	12	1.60563E-03	124.49	0.22114
	16	17	7.11920E-04	56.47	0.18032
	10	9	6.38290E-04	333.41	3.93790
	7	16	1.26360E-04	33.22	0.06268
Case II: 6 subsets	6	32	1.08852E-03	4.13	0.03098
	4	28	8.31382E-04	145.56	0.06857
	2	38	7.49151E-04	4.05	0.05132
	5	32	2.37949E-04	2.89	0.05457
	3	28	2.28982E-04	1.04	0.16719
	1	29	4.33302E-05	1.14	0.10178
Case III:	1	53	2.98760E-04	1.32	0.03930
Case IV:	1	187	1.64510E-04	1.24	0.0134

Table II. Results obtained in the third case of grouping spectra using RDANNM

EXP. NO.	RESPONSE	RESPONSE	RESPONSE	RESPONSE	MEAN	SIGNAL-NOISE R
	1	2	3	4		
1	2.3826e-4	3.0674e-4	2.1993e-4	2.9707e-4	0.0002655	0.00023826
2	4.7882e-4	3.4179e-4	5.1087e-4	0.0011	0.00060787	0.00047882
3	2.5480e-4	2.6622e-4	2.8750e-4	6.8247e-4	0.00037275	0.0002548
4	3.2026e-4	0.0016	0.0049	5.0109e-4	0.00183034	0.00032026
5	3.8840e-4	2.4548e-4	2.6689e-4	0.0019	0.00070019	0.0003884
6	2.2511e-4	2.8601e-4	2.5000e-4	5.6791e-4	0.00033226	0.00022511
7	8.3234e-4	3.7524e-4	6.0654e-4	0.0036	0.00135353	0.00083234
8	2.6165e-4	0.0023	2.4770e-4	7.3435e-4	0.00088592	0.00026165
9	6.4689e-4	0.0043	9.5868e-4	0.0013	0.00180139	0.00064689

Table III. Results obtained in the fourth case of grouping spectra using RDANNM

EXP. No.	RESPONSE 1	RESPONSE 2	RESPONSE 3	RESPONSE 4	MEAN	SIGNAL-NOISE R
1	3.316E-04	2.416E-04	2.350E-04	3.035E-04	2.779E-04	3.316E-04
2	2.213E-04	3.087E-04	3.646E-04	2.630E-04	2.894E-04	2.213E-04
3	4.193E-04	3.658E-04	3.411E-04	2.868E-04	3.533E-04	4.193E-04
4	2.585E-04	2.278E-04	2.695E-04	3.741E-04	2.825E-04	2.585E-04
5	2.678E-04	3.692E-04	3.087E-04	3.988E-04	3.361E-04	2.678E-04
6	2.713E-04	2.793E-04	2.041E-04	3.970E-04	2.879E-04	2.713E-04
7	2.247E-04	7.109E-04	3.723E-04	2.733E-04	3.953E-04	2.247E-04
8	3.952E-04	5.944E-04	2.657E-04	3.522E-04	4.019E-04	3.952E-04
9	5.425E-04	3.893E-04	3.374E-04	4.437E-04	4.282E-04	5.425E-04

The results obtained demonstrate that the ANN designed in the fourth case, has the best learning and generalization capability because the amount of information used to train and test the neural net. However, despite the high learning and generalization capability of the optimized neural network, the information available for training ANN in the neutron spectrometry research area is still not enough when a feed forward ANN trained with back-propagation learning algorithm is used. More research is needed to overcome these drawbacks.

After RDANNM was finished for the cases III and IV of grouping spectra, several testing trials using the optimized design parameters were carried out to observe the behavior of the trained networks. Fig. 3 shows a comparison of the Chi square and correlation tests of the cases III and IV.

From this figure can be observed that in both cases, the tested neutron spectra, 12 for case III and 37 for case IV, are

near from 0 in the Chi square test and from 1 in the correlation test, this means that the performance and generalization capability of the trained network, using the design parameters selected with the RDANNM are high. However, when each neutron spectra was analyzed individually, the unfolded spectra of case III were poor compared with those of case IV.

Figure 4 shows two particular cases of the tested neuron spectra of case IV. Opposite to case III, from this figure can be seen that the spectra unfolded by the trained network is very similar to the expected spectrum extracted from the IAEA compilation.

The anterior demonstrate the powerful of this methodology in the near optimum selection of ANN design parameters. However, as mentioned, the quality and quantity of information used to train the optimized neural network has a great repercussion in the learning and generalization capability of the net.




Fig. 3. Chi square and correlation tests at testing stage of optimized ANN

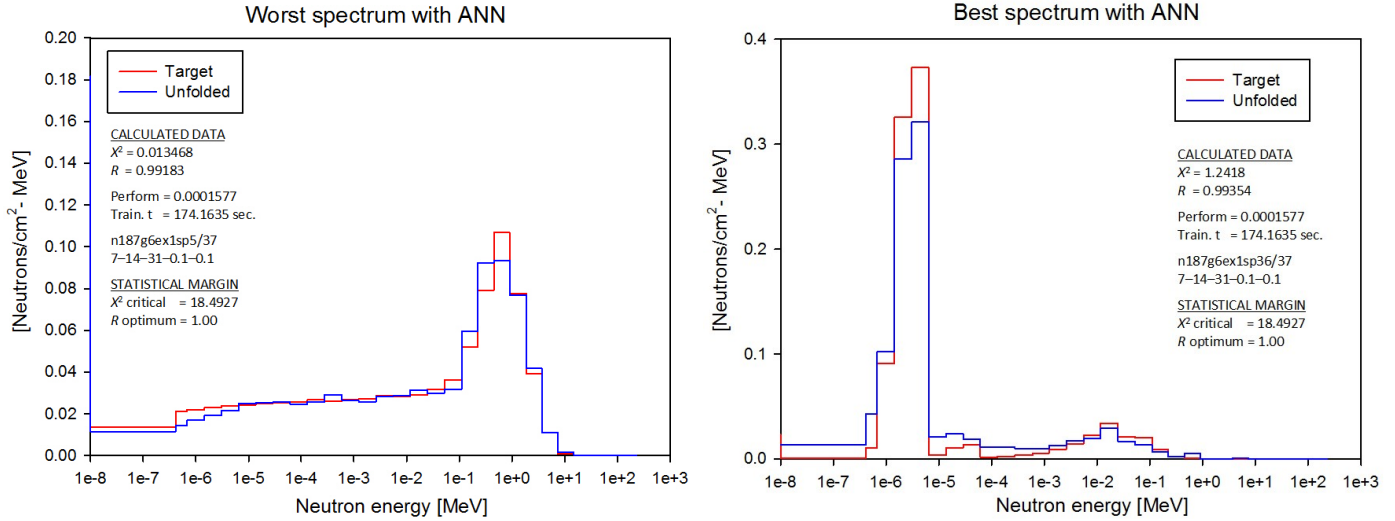


Fig. 4. Two particular cases of neutron spectra at testing stage of optimized ANN

With the results obtained in the four cases studied, and observing the OAs generated, it was possible to see that there is a direct relationship between the general OA performance and the error established like objective function for the OA (in this case $1E-4$) and an inverse relationship between the general OA performance and the OA's output (Signal-to-Noise Ratio). If the mean of OA's performance of the ANNs is reached or near of the established value, the OA will generate a proposal with parameters of high quality in order to determine the best ANN architectural and learning parameters. This relation could be expressed as follows:

$$\frac{\sum_{i=1}^n OAP}{n} \propto \frac{E_{target}}{OAL_{output}} \quad (2)$$

Where AOP is the general Orthogonal Array Performance, i is number of OA trial, n is the total number of data, E_{target} is the error established and OAL_{output} is the output OA Learning by using the best proposed values. It must be highlighted that this relationship could be seeing because the application of the RDANNM.

IV. CONCLUSIONS

In this work, the systematic and experimental strategy known as RDANNM was used for the robust design of feed-forward ANN trained by back-propagation learning algorithm applied in the solution of the neutron spectrometry problem. The application of this methodology has led to the identification of a set of design parameters that enable ANN trained by back-propagation algorithm to produce much better performance than achieved with the conventional trial and error approach.

The optimum design parameter are: The proper density for training samples in the input space was: 80% for ANN training stage and 20% for testing stage.

The best time to stop training to avoid overfitting is variable and depends of the proper selection of the ANN parameters.

In the optimum ANN designed, the best time to train the network avoiding the overfitting was 120 seconds average.

The best architecture to use is 7:14:31, a learning rate = 0.1 and a momentum = 0.1, a trainscg training algorithm and an mse = $1E-4$.

From the four cases considered it is better to use an optimum architecture, designed with the RDANNM, which not overfit the data and do not require more training time instead of using a large architecture stopping the training over the time or trials which produce a poor ANN.

The random weight initialization introduced a great amount of noise in training data which affects significantly the performance of the network. Such initialization introduces large negative number which is very harmful for the unfolded neutron spectra, which has not physics meaning. In consequence, can be concluded that it is necessary to reduce the noise introduced in the random weight initialization. More research is needed to overcome this drawback.

Applying RDANNM to unfold neutron spectra, was observed a relationship between performance, learning and error.

The results obtained in this work reveal that the robust design of artificial neural networks methodology offer potential benefits in the evaluation of the behavior of the net as well as the ability to examine the interaction of the weights and neurons inside the same one.

ACKNOWLEDGMENTS

This work was partially supported by Fondo Sectorial de Investigación para la Educación, under contract 241771.

REFERENCES

- [1] D. J. Thomas, Neutron spectrometry for radiation protection. *Radiation Protection Dosimetry*, 110(1-4):141–149, 2004.
- [2] F. D. Brooks and H. Klein, Neutron spectrometry, historical review and present status. *Nuclear Instruments and Methods in Physics Research A*, 476:1–11, 2002.
- [3] B. R. L. Siebert, J. C. McDonald and W. G. Alberts, Neutron spectrometry for radiation protection purposes. *Nuclear Instruments and Methods in Physics Research A*, 476(12):347–352, 2002.
- [4] R.L. Bramblett, R.I. Ewing and T.W. Bonner, A new type of neutron spectrometer. *Nuclear Instruments and Methods*, 9:1–12, 1960.
- [5] M. Matzke, Unfolding procedures. *Radiation Protection Dosimetry*, 107(1-3):155–174, 2003.
- [6] D.A. Chambless and J.A. Broadway, Comments on neutron spectral unfolding using the monte carlo method. *Nuclear Instruments and Methods*, 214:543–545, 1983.
- [7] M. Tomas, F. Fernandez, M. Bakali, and H. Muller, MITOM: a new unfolding code based on a spectra model method applied to neutron spectrometry. *Radiation Protection Dosimetry*, 110(1-4):545–548, 2004.
- [8] J. Weezy, N.E. Hertel and K. Veinot, BUMS–Bonner sphere unfolding made simple: an html based multisphere neutron spectrometer unfolding package. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 476(1-2):263–269, 2002.
- [9] D.W. Freeman, D.R. Edwards, and A.E. Bolon, Genetic algorithms - a new technique for solving a neutron spectrum unfolding problem. *Nuclear Instruments and Methods in Physics Research A*, 425(3):549–576, 1999.
- [10] B. Mukherjee, Andi-03: a genetic algorithm tool for the analysis of activation detector data to unfold high-energy neutron spectra. *Radiation Protection Dosimetry*, 110(14):249–254, 2004.
- [11] H.R. Vega-Carrillo, V.M. Hernandez-Davila, E. Manzanares-Acuña, G.A. Mercado-Sanchez, M.P. Iñiguez de la Torre, R. Barquero, S. Preciado-Flores, R. Mendez-Villafañe, T. Arteaga-Arteaga, and J.M. Ortiz-Rodriguez, Neutron spectrometry using artificial neural networks. *Radiation Measurements*, 41:425–431, 2006.
- [12] H.R. Vega-Carrillo, M.R. Martinez-Blanco, V.M. Hernandez-Davila, and J.M. Ortiz-Rodriguez, Spectra and dose with ANN of ^{252}Cf , $^{241}\text{AmBe}$ and $^{239}\text{PuBe}$. *Journal of Radioanalytical and Nuclear Chemistry*, 281(3):615–618, 2009.
- [13] H.R. Vega-Carrillo, M.R. Martinez-Blanco, V.M. Hernandez-Davila, and J.M. Ortiz-Rodriguez, Ann in spectroscopy and neutron dosimetry. *Journal of Radioanalytical and Nuclear Chemistry*, 281(3):615–618, 2009a.
- [14] T. Munakata, *Fundamentals of the new artificial intelligence, neural, evolutionary, fuzzy and more*. Springer, 2008.
- [15] A.I. Galushkin, *Neural networks theory*. Springer, 2007.
- [16] D. Graupe, *Principles of artificial neural networks*. World Scientific, 2007.
- [17] G. Dreyfus, *Neural networks, methodology and applications*. Springer, 2005.
- [18] J. Lakhmi and A.M. Fanelli *Recent advances in artificial neural networks design and applications*. CRC Press, 2000.
- [19] G.E. Peterson, D.C. St. Clair, S.R. Aylward, and W. E. Bond, Using taguchi's method of experimental design to control errors in layered perceptrons. *IEEE Transactions on Neural Networks*, 6(4):949–961, 1995.
- [20] J.A. Frenie and A. Jiju, Teaching the taguchi method to industrial engineers. *MCB University Press*, 50(4):141–149, 2001.
- [21] M.S. Packianather, P.R. Drake, and H. Rowlands, Optimizing the parameters of multilayered feedforward neural networks through taguchi design of experiments. *Quality and Reliability Engineering International*, 16:461–473, 2000.

Automatización del proceso de entrenamiento de redes neuronales de regresión generalizada aplicadas a la espectrometría de neutrones

Ma del Rosario Martínez-Blanco^{1-4,6,*}, Víctor Hugo Castañeda-Miranda¹⁻⁴, Luis Octavio Solís-Sánchez^{1-4,6}, Rodrigo Castañeda-Miranda^{1-4,6}, Gerardo Ornelas-Vargas^{1-4,6}, Héctor Alonso Guerrero-Osuna^{1-4,6}, Hector Rene Vega-Carrillo^{1,5,6}, José Manuel Ortiz-Rodríguez^{1-4,6}

¹Universidad Autónoma de Zacatecas

²Laboratorio Nacional en Investigación, Desarrollo Tecnológico e Innovación en Sistemas Embebidos, Diseño Electrónico Avanzado y Microsistemas

³Laboratorio de Innovación y Desarrollo Tecnológico en Inteligencia Artificial

⁴Centro de Investigación e Innovación Tecnológica Industrial

⁵Unidad Académica de Estudios Nucleares

⁶Unidad Académica de Ingeniería Eléctrica

*Email: mrosariomb@yahoo.com.mx

Resumen

El proceso de reconstrucción del espectro neutrónico ha sido objeto de investigación durante muchos años. El uso del espectrómetro de esferas Bonner es un método bien establecido para medir la distribución de energía en fuentes de emisión de neutrones. Sin embargo, la derivación de la información espectral no es simple debido a que el dato desconocido no se da directamente como resultado de las mediciones. Monte Carlo, los métodos iterativos y el principio de la máxima entropía, son algunos de los métodos utilizados. Los inconvenientes asociados con estos procedimientos tradicionales han motivado enfoques complementarios basados en la tecnología de inteligencia artificial. Las redes neuronales artificiales de propagación inversa han sido el procedimiento más utilizado para realizar la espectrometría neutrónica, sin embargo la determinación de los parámetros óptimos de la arquitectura de red es un proceso complejo. Actualmente, los investigadores emplean la técnica de ensayo y error, la cual no proporciona certeza alguna de encontrar la mejor topología de red. A diferencia de las redes de propagación inversa que emplean una gran cantidad de tiempo en el proceso debido a las múltiples iteraciones necesarias, las redes neuronales de regresión generalizada solo requieren de un parámetro para el entrenamiento, mismo que se realiza en una sola iteración, reduciendo significativamente el tiempo empleado en el entrenamiento, sin embargo uno de los inconvenientes es la falta de herramientas científicas, metodológicas y sistemáticas que permitan emplear esta tecnología en aplicaciones reales. El objetivo de este trabajo fue diseñar una herramienta científico-tecnológica basada en redes neuronales artificiales de regresión generalizada en el ámbito de espectrometría neutrónica, empleando como única pieza de información las lecturas tomadas con un sistema espectrométrico de esferas Bonner, que permita resolver con alto desempeño y capacidad de generalización el problema de la espectrometría de neutrones. Para realizar el entrenamiento y prueba de la red neuronal se diseñó una herramienta computacional que automatiza los procesos inmersos en el entrenamiento de la red. Los resultados obtenidos muestran que la red neuronal de regresión generalizada es capaz de predecir el espectro de neutrones desconocido con alto desempeño y capacidad de generalización, muestran también que la herramienta desarrollada y automatizada disminuye el tiempo de pre-procesamiento, procesamiento, análisis y pos-procesamiento de información así como el riesgo de errores humanos durante el análisis de la información.

Palabras clave: Espectrometría de neutrones; dosimetría de neutrones; esferas Bonner

Herramienta en Software para Resolución de Problemas Inversos mediante Técnicas de Inteligencia Artificial: Una Aplicación en Espectrometría Neutrónica

V.H. Castañeda-Miranda¹⁻⁵, M.R. Martínez-Blanco¹⁻⁵, L.O. Solís-Sánchez¹⁻⁵
R. Castañeda-Miranda¹⁻⁵, A.A. León-Pérez¹, C.F. Hernández-Pérez¹
J.G. Espinoza-García¹, H.R. Vega-Carrillo⁶, R. Méndez⁷, E. Gallego⁸
M.A. Sousa Lacerda⁹, J.M. Ortiz-Rodríguez¹⁻⁵

¹*Universidad Autónoma de Zacatecas*

²*Laboratorio Nacional en Investigación, Desarrollo Tecnológico e Innovación en Sistemas Embebidos, Diseño Electrónico Avanzado y Microsistemas.*

³*Laboratorio de Innovación y Desarrollo Tecnológico en Inteligencia Artificial (LIDTIA).*

⁴*Centro de Investigación e Innovación Tecnológica Industrial (CIITI).*

⁵*Unidad Académica de Ingeniería Eléctrica.*

⁶*Unidad Académica de Estudios Nucleares (UAEN).*

⁷*Laboratorio de Patrones Neutrónicos del Departamento de Metrología de Radiaciones Ionizantes del Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas.
Av. Complutense, 22, 28040, Madrid, España.*

⁸*Departamento de Ingeniería Nuclear de la Universidad Politécnica de Madrid
C. José Gutiérrez Abascal, 2, 28006, Madrid España.*

⁹*Centro de Investigación de Tecnología Nuclear de la Comisión Nacional de Energía Nuclear
Av. Presidente Antonio Carlos, 6627, Pampulha, CEP: 31270-901, Belo Horizonte, MG, Brazil*

Resumen

La metodología Taguchi ha resultado ser de gran eficiente para resolver problemas inversos, en los cuales los valores de algunos parámetros del modelo deben ser obtenidos de los datos observados. Hay características matemáticas intrínsecas que hacen que un problema se denomine de tipo inverso. Los problemas inversos aparecen en muchas ramas de la ciencia, la ingeniería y las matemáticas. Para resolver este tipo de problemas, los investigadores han utilizado distintas técnicas. Recientemente, el uso de técnicas

basadas en la tecnología de Inteligencia Artificial está siendo explorada por los investigadores. En este trabajo se presenta el uso de una herramienta de software basada en redes neuronales artificiales de regresión generalizada en la solución de problemas inversos con aplicación en física de altas energías, específicamente, en la solución del problema de espectrometría de neutrones. Para resolver el problema antes mencionado se utiliza una herramienta en Software desarrollada en el ambiente de programación de MatLab, que emplea una interface gráfica de usuario amigable, intuitiva y de fácil manejo para el usuario. Esta herramienta computacional resuelve el problema inverso involucrado en la reconstrucción del espectro de neutrones en base a las mediciones realizadas con un sistema espectrométrico de esferas Bonner. Al introducir la información antes mencionada, la red neuronal es capaz de reconstruir el espectro de neutrones con alto desempeño y capacidad de generalización. La herramienta permite que el usuario final no requiera gran capacitación ni conocimientos técnicos en desarrollo y/o uso de software, por lo que facilita el uso del programa para la resolución de problemas inversos que se tienen en varios ámbitos del conocimiento. Las técnicas de Inteligencia Artificial presentan singular veracidad para resolver problemas inversos, dadas las características propias de las Redes Neuronales Artificiales y su topología de red, por ello, la herramienta desarrollada ha sido de gran utilidad, puesto que los resultados que genera la Red Neuronal Artificial requieren de poco tiempo en comparación a otras técnicas y son resultados correctos comparándolos con los datos reales del experimento.

Palabras clave: Metodología Taguchi, Espectrometría de neutrones; dosimetría de neutrones; RNA de IA; Software

1.- Introducción

EL ser humano es consciente de la importancia que tienen los temas de dosimetría y espectrometría en cuestiones de salud al estar expuesto a radiaciones, las limitaciones tecnológicas que se tenían hace varios años no han permitido tener métodos para una pronta cuantificación de los neutrones en el ambiente, es por ello que requiere una herramienta que de manera rápida y segura, genere la certeza de saber cuales son las condiciones en las que se encuentran distintos ambientes de trabajo donde interactúa el ser humano y están expuestos a la generación de neutrones y de esta manera proponer como prevenir esta radiación.

Al hablar de dosimetría y espectrometría de neutrones, hacemos referencia a partículas subatómicas con un nucleón y sin carga neta, lo que los convierte prácticamente imposibles de medir, por tanto, para la detección de neutrones existe una gran variedad de soluciones, una de ellas son las esferas Bonner [Bakali, 2001].

Las mediciones realizadas por las esferas Bonner podemos relacionarlas con la ecuación de Fredholm, en la cual se expresan un producto de convolución que cabe mencionar es un problema complicado de resolver, dado que cuenta con un gran número de incógnitas y pocas ecuaciones [Bakali, 2001]. Dentro de las técnicas mediante las que se puede resolver la ecuación de Fredholm tenemos el método Monte Carlo, métodos iterativos y en este artículo se propone el uso de la Inteligencia Artificial pues han demostrado tener una gran eficiencia. La inteligencia artificial (IA) es un área multidisciplinaria, que a través de ciencias como las ciencias de la computación, la matemática, la lógica y la filosofía, estudia la creación y diseño de sistemas capaces de resolver problemas cotidianos por sí mismas utilizando como paradigma la inteligencia humana, la creación de la inteligencia artificial no debe ser una copia exacta de la inteligencia humana [Lotman, 1994].

Dentro de la inteligencia artificial surgen varios ramos, como las “Redes Neuronales Artificiales (RNA)” que imitan el proceso de aprendizaje del cerebro mediante una estructura de neuronas artificiales [De Moya et al., 1998].

Una RNA consiste en gran número de elementos de procesamiento simples que están interconectados uno con el otro y también entre capas [Rong-Choi & King-Chu, 2013].

Una RNA de BP consiste en un conjunto de entradas y unidades de procesamiento llamadas nodos, las neuronas en cada capa son totalmente interconectados por pesos que junto con la arquitectura de red almacenan el conocimiento de una red, donde además del procesamiento neuronas, hay un sesgo en cada neurona conectado, la cual esta conectada a el procesamiento en las capas ocultas y de salida, así mismo, el número de capas y neuronas ocultas dentro de cada capa puede variar dependiendo del tamaño y la naturaleza de el conjunto de datos [Kaastra & Boyd, 1996]. Uno de los destacados problemas de este tipo de red es que no se tiene una arquitectura de red especifica para cada problemática. En la figura 1 se ilustra un red neuronal.




Figura 1.- Elementos de una red neuronal artificial.

Mediante el desarrollo de una herramienta automatizada en la plataforma de software de MatLab, basada en redes neuronales artificiales de regresión generalizada se le da solución a problemas inversos, la cuál emplea un interface gráfica de usuario denominado “GUI”, dicha herramienta resulta intuitiva y de fácil manejo para el usuario.

La herramienta antes mencionada tendrá una optimización mediante tecnología robusta desarrollada por el Dr. Genichi Taguchi, la cual se utiliza para desarrollar familias de productos en lugar de un producto cada vez. El resultado directo de este enfoque es el

desarrollo de productos de calidad robusta y funcionamiento seguro durante su uso [Wu & Wu, 1996].

La robustez de la herramienta de Software desarrollada se puede aplicar en múltiples campos de la ingeniería y otras ciencias para distintas aplicaciones, entre las que destacan reconocimiento de patrones, reconocimiento de imágenes, invernaderos, espectrometría y dosimetría [Martínez-Blanco, et al., 2006], etc.

Donde con esta herramienta de Software, se resuelve el problema inverso involucrado en la reconstrucción del espectro de neutrones en base a las mediciones realizadas con un sistema espectrómetro de esferas Bonner. Al introducir la información antes mencionada, la red neuronal es capaz de reconstruir el espectro de neutrones con alto desempeño y capacidad de generalización, de igual manera, se requieren de poco tiempo en comparación a otras técnicas y son resultados correctos comparándolos con los datos reales del experimento.

2.- Materiales y Métodos

Las etapas de realizar se pueden ver en el siguiente diagrama a cuadros:



1. El primer método usado para la elaboración de este producto, es el diseño robusto el cual se ilustra en la figura 2.

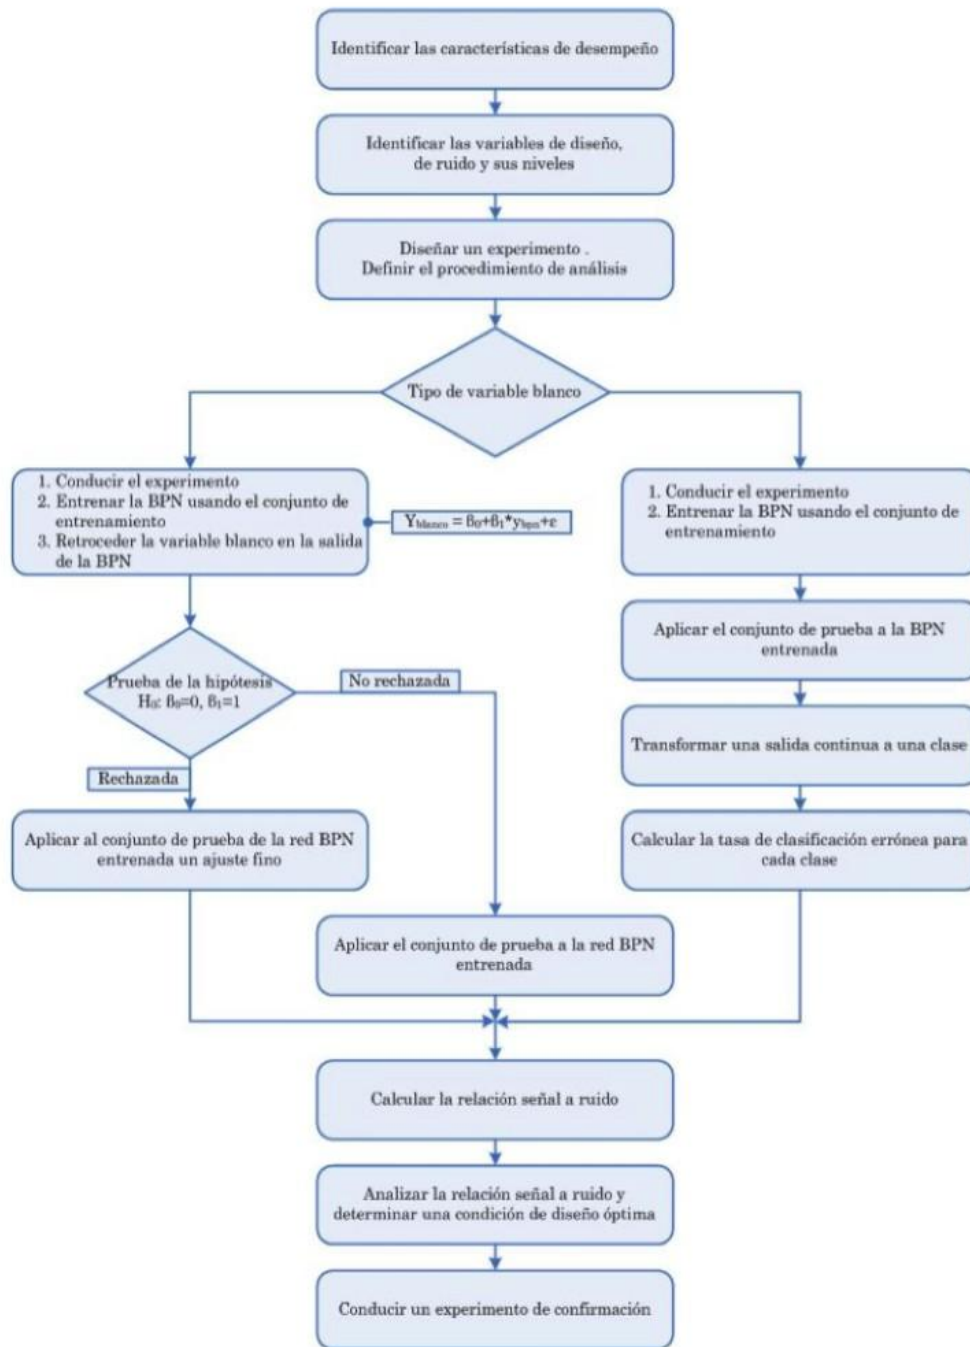


Figura 2.- Diagrama de flujo del Diseño Robusto

Diseño robusto

Los primeros tres incisos hacen referencia a identificar las variables de diseño y de ruido, es ahí donde se definen cuatro intervalos de búsqueda, entre el número de capas, el número de neuronas, el momento y la tasa de aprendizaje. Una vez definido nuestra área donde se buscara la mejor arquitectura de red, el diseño se hace robusto pues intervienen las variables de ruido, como lo son el porcentaje de entrenamiento y validación, el conjunto inicial aleatorio de pesos y la solución conjunto entrenamiento-prueba.

Estos parámetros se trabajan mediante la metodología desarrollada por el Dr. Geníchi Taguchi en 1950 quien ideó una aplicación estadística para mejorar la calidad de los productos manufacturados. Cabe señalar que el Dr. Taguchi hace hincapié en que es más barato rediseñar los procesos de fabricación y productos que realizar acciones de mejora de la calidad tras una auditoría [ASI, 2013].

Taguchi hizo contribuciones muy importantes a la estadística industrial, cuyos elementos clave de su filosofía de calidad son:

- I. La Función de pérdida Taguchi, utilizada para medir la calidad de un producto o servicio.
- II. Innovaciones en el diseño de experimentos, mediante el uso de una matriz de factores de ruido no controlables en la vida real, pero cuya variabilidad es sistematizada en el experimento.
- III. La filosofía de la Ingeniería de la calidad fuera de línea o metodología Taguchi, que esta basada en el diseño de productos y procesos de tal modo que proporcionen su función de la manera más robusta posible, siendo insensibles a las influencias de factores externos al diseño conocidos como factores de ruido.

La filosofía de la Ingeniería de la calidad fuera de línea o metodología Taguchi, es la que se utilizara como método de optimización en este tema de tesis, dado que su potencial es el poderlo usar en entorno experimental, tampoco es necesario conocer un conjunto de ecuaciones para llevar a cabo su optimización, por lo cuál se adecua idealmente a nuestras necesidades.

La metodología Taguchi se basa en arreglos ortogonales donde se determinaran los valores de los parámetros que proporcionen el mejor resultado definido por quien lleva a cabo el experimento. Mediante la optimización de la relación “señal a ruido”, el sistema se vuelve robusto a perturbaciones incontrolables, donde se asimila como ruido los factores incontrolables [Martínez-Blanco et al., 2006]. Dentro de un arreglo ortogonal, los parámetros controlables y de ruido tienen un número finito de niveles. En siguiente tabla se muestra el arreglo Ortogonal $L_9(3^4)$ y $L_4(2^4)$.

Tabla 1.- Arreglo ortogonal $L_9(3^4)$ y $L_4(2^4)$.

Exp. No	A	B	C	D	S1	S2	S3	S4	PROMEDIO	RELACION S-R
1	1	1	1	1						
2	1	2	2	2						
3	1	3	3	3						
4	2	1	2	3						
5	2	2	3	1						
6	2	3	1	2						
7	3	1	3	2						
8	3	2	1	3						
9	3	3	2	1						

Arreglo Ortogonal $L_9(3^4)$ y $L_4(2^4)$

De la tabla se observan los cuatro parámetros mediante las letras A, B, C y D, cada parámetro tiene tres niveles, mientras que los parámetros de ruido están señalados como S1, S2, S3 y S4.

Mediante los nueve experimentos con las cuatro parámetros tenemos 36 posibles combinaciones de parámetros y mediante los nueve experimentos con las cuatro señales de ruido tenemos 36 posibles combinaciones de ruido, por tanto se tienen 1296 posibles combinaciones del sistema robusto. Es por ello que la metodología Taguchi proporciona una eficiencia tal que permite considerar simultáneamente los efectos de los variables parámetros de diseño, con lo cual se mejora el desempeño de manera cuántica respecto al esfuerzo que se requiere.

El resumen del proceso que conlleva la metodología Taguchi se muestra a continuación:

1. Determinar las características de calidad a ser optimizadas
2. Identificar los factores de ruido y las condiciones de prueba
3. Identificar los factores de control y sus niveles alternativos
4. Diseñar la matriz de experimentos y definir el procedimiento de análisis de datos
5. Conducir la matriz de experimentos
6. Analizar los datos y determinar los niveles óptimos de los factores de control
7. Pronosticar el desempeño a estos niveles

Etapas de la metodología Taguchi

Se automatizó el proceso del diseño robusto para que se realicen las 36 arquitecturas de red del arreglo ortogonal con la metodología Taguchi. Una vez completo el arreglo ortogonal, se realiza un proceso estadístico que consiste en:

- Asignar la matriz de entrenamiento y prueba
- Asignar el tipo de RNA, en este caso de GRANN
- Hacer la simulación de red
- Calcular los mínimos cuadrados
- Calcular la correlación
- Calcular la chi cuadrada, χ^2 .
- Calcular el desempeño
- Hacer el ajuste estadístico

Con ello se pueden determinar el mejor desempeño entre los 36 posibles y es este el que genera la mejor arquitectura de Red.

2. La plataforma tipo GUI en la cual se realizara el experimento se puede observar en la figura 3.

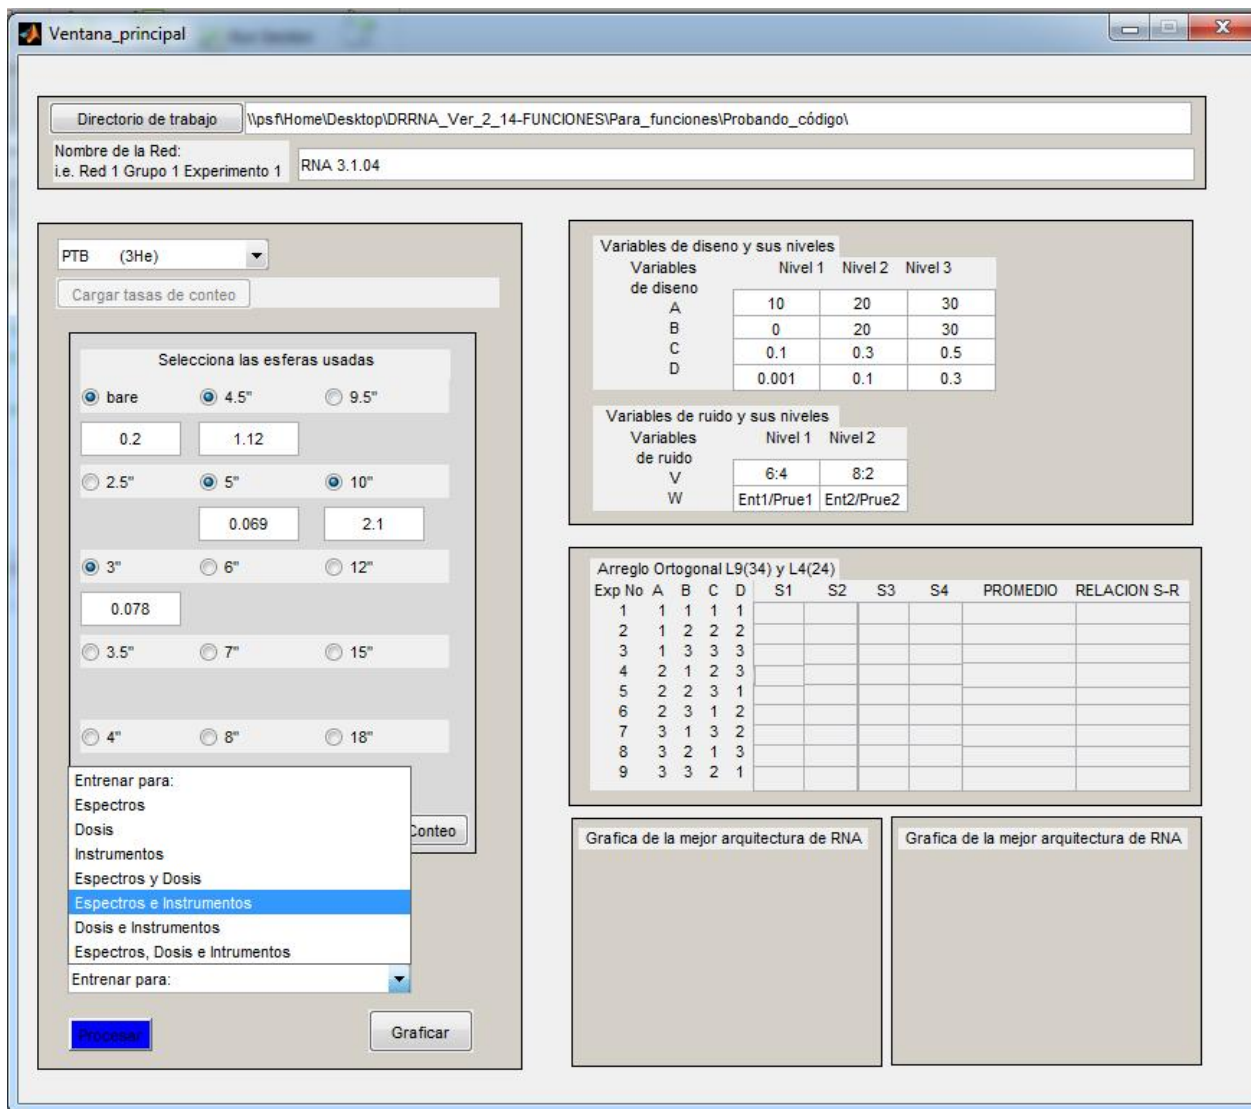


Figura 3. Plataforma GUI para realizar los experimentos.

Dentro de las posibilidades de la interface tenemos:

- Seleccionar un directorio de trabajo con interacción tipo Windows
- Designarle una etiqueta a la RNA

-
- Seleccionar el tipo de laboratorio a trabajar y con base a ello se generaran el tipo de Esferas Bonner disponibles
 - Seleccionar las Esferas Bonner deseadas
 - Cargar las Tasas de Conteo de las Esferas Bonner seleccionadas
 - Escoger el tipo de entrenamiento de la RNA
 - Usar las variables de diseño por default o reasignar por los valores deseados
 - Usar las variables de ruido por default o reasignar por los valores deseados

Una vez que asignamos todas las variables de nuestro diseño de RNA, seleccionamos PROCESAR y se comienza a trabajar de manera autónoma para la generación de las 36 distintas arquitecturas de red, las cuales se irán colocando sus valores dentro del arreglo ortogonal Taguchi.

Al final del llenado del arreglo ortogonal se seleccionara la mejor arquitectura de red y los valores de la RNA optima se graficaran en los cuadros inferiores.

3.- Conclusión

Se ha diseñado una interface que reduce el tiempo para encontrar una arquitectura de red optima conforme a métodos anteriores. Este interface también reduce el error humano y la interacción grafica que se tiene hace el ambiente de trabajo mas viable para el uso del software.

Agradecimientos

Este trabajo fue parcialmente financiado por: el Fondo de Investigación para la Educación bajo contrato 241771, Fondos Mixtos SEP-CONACYT bajo contrato ZAC-C03-2015-26357-4 y por PROSOFT bajo contrato 201513723. El primero, tercero y cuarto autor agradecen la beca de Licenciatura con número de becario 23241, 23238 y 23240 respectivamente, recibido por Fondo Sectorial de Investigación para la Educación bajo contrato 241771. El segundo y quinto autor agradecen a la beca de Doctorado con número de becario 23386 y 23385 respectivamente, recibido por Fondo Sectorial de Investigación para la educación bajo contrato 241771.

Referencias

- Bakali, M. (2001). *Espectrometría neutrónica en las centrales nucleares mediante un sistema de esferas Bonner*. Tesis doctoral, Universitat Autònoma de Barcelona.
- De Moya Anegón, F., Herrero Solana, V. & Guerrero Bote, V. (1998). *La aplicación de Redes Neuronales Artificiales (RNA): A la recuperación de la información*. Texto completo.
- Kaastra, I. & Boyd, M. (1996). *Designing a Neural Network for forecasting financial and economic time series*. *Neurocomputing* **10**: 215-236.

-
- Lotman, I. (1994). *Cerebro-texto-cultura-inteligencia artificial*. Semiosfera: Humanidades-Tecnologías 2: 73-100.
- Martínez-Blanco, M. R., Ortiz-Rodríguez, J. M., & Vega-Carrillo, H. R. (2006). *Espectrometría de neutrones y cálculo de dosis equivalentes, aplicando la metodología de diseño robusto de redes neuronales artificiales*. Encuentro de Investigación en Ingeniería Eléctrica, ENINVIE 2006, Zacatecas, Zac. 5-7 de Abril. Pp. 301-306.
- Rong-Choi, L. & King-Chu, H. (2013). *An automatic vehicle license plate recognition base don Prewitt Edge detection and Artificial Neural Network*. International Journal of Scientific Research and Education 5: 79-90.
- Wu, Y. & Wu, A. (1996). *DISEÑO ROBUSTO UTILIZANDO LOS MÉTODOS DE TAGUCHI*. Ediciones Díaz de Santos. Madrid.
- ASI. [Online]. *ASI mourns the loss of Dr. Genichi Taguchi*. <<http://asiusa.com/asi-mourns-loss-dr-genichi-taguchi/>>. ASI Consulting Group. [Consultada en Noviembre de 2015]. (2013).

Detección de cáncer de mama usando técnicas avanzadas de minería de datos con redes neuronales

Jorge Armando Ortiz Murillo¹⁻⁴, José María Celaya Padilla¹⁻⁴, María Del Rosario Martínez Blanco¹⁻⁴, Luis Octavio Solís Sánchez¹⁻⁴, Rodrigo Castañeda Miranda¹⁻⁴, Idalia Garza Veloz¹⁻³, Margarita Martínez Fierro¹⁻³, Yamilé López Hernández¹⁻³, José Manuel Ortiz Rodríguez¹⁻⁴

Universidad Autónoma de Zacatecas, Av. Ramón López Velarde 801, Col. Centro 98000 Zacatecas, México:

¹Centro de Investigación e Innovación Tecnológica Industrial (CIITI)

²Laboratorio de Innovación y Desarrollo Tecnológico en Inteligencia Artificial, (LIDTIA)

³Laboratorio de Bioinformática

⁴Unidad Académica de Ingeniería Eléctrica (UAIE)

Abstract

El cáncer de mama es uno de los problemas de salud más grandes a nivel mundial, es el cáncer más diagnosticado en mujeres y la prevención parece imposible ya que su causa es desconocida, debido a esto, la detección temprana juega un papel fundamental en el pronóstico del paciente. En países en desarrollo como México donde el acceso a servicios especializados de salud es escaso, la revisión clínica regular es poco frecuente y no se cuenta con suficientes radiólogos. La forma más común de detección del cáncer de mama es la auto examinación pero esta solo se detecta en etapas más avanzadas, cuando ya es palpable. Debido a lo anterior, el objetivo del presente trabajo es crear un sistema de Diagnóstico Asistido por computadora (CADx) empleando técnicas de análisis de información como minería de datos y técnicas avanzadas de Inteligencia Artificial, buscando ofrecer un diagnóstico médico previo o segunda opinión, como si fuera un segundo radiólogo con el objetivo de ayudar a reducir los índices de mortalidad por cáncer de mama. En este trabajo se presentan avances obtenidos en el diseño de algoritmos computacionales empleando técnicas de visión computacional para la extracción de características derivadas de mamografías. Utilizando técnicas de análisis de información big data con minería de datos, es posible identificar a pacientes con un alto riesgo de cáncer de mama. Con la información obtenida del análisis de las mamografías, el objetivo en la etapa siguiente será establecer una metodología para la generación de bio-marcadores imagenológicos que permitan establecer

un índice de riesgo de cáncer de mama para pacientes mexicanos, en esta primera etapa se presentan resultados de la clasificación de pacientes con alto y bajo riesgo de padecer cáncer de mama utilizando redes neuronales.

Keywords: *Cáncer de mama, visión computacional, minería de datos y redes neuronales.*

1.- INTRODUCCION

1.1 Industria 4.0

El termino Industria 4.0 fue mencionado por primera vez en a “Hannover Fair” con la presentación de la iniciativa “Industry 4.0”. La primera revolución industrial “Mecanización” como resultado de la invención de la máquina de vapor, la segunda “Producción en masa” con la ayuda de la electricidad, la tercera “Digitalización” con el uso la Electrónica y las Tecnologías de Información, esto marca la venida de la cuarta revolución industrial con el uso de los sistemas físicos cibernéticos por sus siglas en ingles CPS y el internet de las cosas y servicios[1]. El objetivo de la Industria 4.0 es la aparición de fábricas digitales con las siguientes características:

- Creación de redes inteligentes[1].
- Movilidad[1].
- Flexibilidad[1].
- Integración de clientes[1].
- Nuevos modelos de negocio innovadores[1].

1.2 Salud 4.0

La industria 4.0 llegó para quedarse, la digitalización de datos vitales, las recomendaciones para los pacientes, el registro de hábitos cotidianos, es el Big Data aplicado al sector de la salud, el objetivo de muchos productos y soluciones están alineados con incrementar la experiencia de los usuarios, darles información relevante para su salud y ofrecer soluciones, a fin de cuentas se trata de utilizar la tecnología para mejorar la calidad de vida.

1.3 Cáncer de Mama

El cáncer de mama es el problema de salud más significativo del mundo, en México cuenta con aproximadamente 148 mil nuevos casos de cáncer diagnosticados y 78 mil mujeres mueren de cáncer de mama cada año[2], el cáncer de mama es el cáncer más frecuente en mujeres, por el cual el 1% de todas las mujeres viven con el mismo y de morir por el mismo es de 1 cada 26.8[3].

La prevención primaria parece imposible ya que su causa de este cáncer es desconocida, donde la detección temprana es la clave, Los estudios por mamografías son lo más aceptado a nivel mundial, han demostrado tener una efectividad de reducir su índice de mortalidad entre un 30 y 70%[3], pero cuanta con limitaciones de observadores humanos y es difícil para los radiólogos proveer resultados acertados y uniformes es difícil debido a la cantidad de mamografías generadas[2].

Las mujeres cuyos tumores fueron encontrados tempranamente por mamografías, su tasa de supervivencia de cinco años son del 82% y en las que no de 60%[2].

Las limitaciones de los observadores humanos tienen entre 10 y 30% de errores en lesiones de mama, con el procesamiento digital de imagen, reconocimiento de patrones e inteligencia artificial, los radiólogos en promedio incrementan en 10% la sensibilidad[2], debido a los problemas que presentan los revisores humanos, la comunidad científica ha tratado de ayudarles para esto se crearon los sistemas CAD.

Los radiólogos utilizan los sistemas CAD para asistirlo en las fallas de detección de signos de cáncer visibles en las mamografías (CADe) y para asistir en la clasificación de cáncer benigno o maligno y diagnóstico de lesiones (CADx)[4].

Los sistemas CAD pueden detectar pequeños errores ocasionados por los humanos y con esto reducir los falsos negativos, el análisis de imágenes médicas por computadora fue introducido en los 60's por Lusted que sugirió sé que puede analizarse automáticamente para distinguir entre una imagen normal y anormal[4].

Estos son algunos de los problemas que se tienen con el uso de sistemas CAD:

- Micro calcificaciones son muy pequeñas, entre .1 y 1 mm, promedio .3mm y algunas son menores a .1mm, las cuales no pueden ser detectadas en film-screen mamografía de ruido de alta frecuencia[2].
- Micro calcificaciones con diferentes tamaños, formas y distribuciones[2].
- Micro calcificaciones pueden ser de contraste bajo entonces la diferencia de intensidad entre áreas sospechosas y los tejidos circundantes puede ser muy delgada[2].
- Micro calcificación pueden estar muy cerca de los tejidos circundantes y los algoritmos de segmentación simple, no funcionan bien[2].
- En tejidos densos, especialmente en los senos de mujeres jóvenes, las zonas sospechosas son casi invisibles, los tejidos densos en mujeres jóvenes pueden ser fácilmente malinterpretadas como micro calcificaciones y con alta tasa de falsos negativos[2].

1.4 Minería de Datos

En la actualidad la minería de datos se utiliza para resolver varios problemas como por ejemplo la clasificación de correos en spam y no spam, las sugerencias de amigos en facebook, las búsquedas en google, etc. La minería de datos se encarga de hacer que las maquinas aprendan sin ser programadas, mediante el uso de redes neuronales imitando cómo funciona el cerebro humano[5].

Para esto existen diferentes tipos de aprendizaje [5]:

- Supervisado al cual le damos un conjunto de datos “Respuestas correctas” y en base a esos se obtiene otra respuesta correcta, estos a su vez se clasifican:
 - Problemas de regresión, se tiene de salida N datos.
 - Problemas de clasificación, se tiene una salida binaria: bueno y malo, si y no, etc.
- No supervisado, este tipo de aprendizaje se basa en que no se sabe porque característica se van a agrupar los datos.

1.5 Redes Neuronales

Las redes neuronales son algoritmos que intentan imitar el cerebro humano, en los 80's y principios de los 90's eran muy usados pero a fines de los 90's disminuyó su popularidad, actualmente resurgió el uso de las técnicas de su estado de arte para muchas aplicaciones ya que se mejoró la velocidad de procesamiento de las maquinas[5].

En este trabajo se propone una metodología para la detección y clasificación de lesiones de cáncer de mama mediante el uso de mamografías con técnicas de visión computacional y minería de datos.

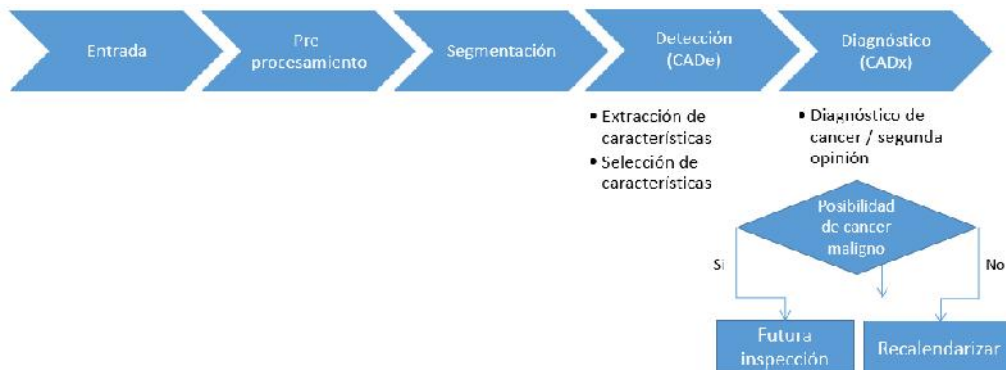
2.- MATERIALES Y METODOS

2.1.- Métodos

La metodología propuesta tiene como objetivo ofrecer una segunda opinión al radiólogo, para esto, se propuso la siguiente metodología en la que se busca imitar los pasos que realiza el radiólogo. Brevemente, primero las imágenes de mamografía son pre-procesadas para realizar y mejorar su visualización. Posteriormente, el radiólogo segmenta las áreas sospechosas donde se encuentra alguna anomalía. Estas lesiones posteriormente son catalogadas como Malignas o Benignas dependiendo del resultado de su biopsia. La metodología propuesta busca evitar el proceso de extracción de biopsias, de tal manera que usando características presentes en la imagen puedan ser usadas como forma de clasificación del tipo de lesión.

En la imagen 1 se muestra el procedimiento que se realizó para la detección de cáncer en las anomalías sin realizar biopsias. Brevemente, al igual que en la metodología utilizada por el radiólogo: en una primera instancia se pre-procesa la imagen, posteriormente se segmentan las áreas sospechosas con alguna anomalía. Utilizando estas áreas sospechosas la metodología propuesta, caracteriza y extrae varias características que permitan en una siguiente etapa generar un modelo de clasificación de lesiones Malignas y Benignas, esta clasificación puede ser usada por el radiólogo como una segunda opinión y evitar el proceso de extracción de biopsias in necesarias.

Imagen 1.- Modelo



2.2.- Materiales

En esta investigación se utilizó la base de datos BCDR-D01 del repositorio digital de cáncer de pecho (bcdri.inegi.up.pt)[6], el dataset está conformado por 79 lesiones de cáncer comprobadas por medio de una biopsia realizada a 64 mujeres, de las cuales se sacaron 143 segmentaciones que incluyen información clínica y descriptores basados en las imágenes[7].

En la tabla 1 se muestra la información clínica y general que se tiene de las biopsias:

Tabla 1.- Información clínica y general

Feature	Description
Age	The age of the patient at the time of the study
Breast Density	The density of the breast at the time of the study according to the BI-RADS standard
Mammography Nodule	The lesion contains a mass
Mammography Calcification	Calcifications were detected in the lesion
Mammography Microcalcification	Microcalcifications were detected in the lesion
Mammography Axillary Adenopathy	Axillary adenopathy detected
Mammography Architectural Distortion	Signs of architectural distortion
Mammography Stroma Distortion	Signs of stroma distortion
Classification	Classification of lesion given by the biopsy result.
Image View	Type of image view (1-RCC, 2-LCC, 3-RO, 4-LO).
Mammography Type	Presence of abnormality.

En la tabla 2 se muestra un conjunto de descriptores de intensidad calculados directamente de los niveles de grises de los pixeles que están dentro de la lesión identificada por los radiólogos.

Tabla 2.- Conjuntos de descriptores de intensidad.

Feature	Description
Mean (i_mean)	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$, with n being the number of pixels inside the region delimited by the contour and x_i being the grey level intensity of the i^{th} pixel inside the contour.
Standard Deviation (i_std)	$\sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2}$
Skewness (i_skewness)	$\frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left(\sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \right)^3}$
Kurtosis (i_kurtosis)	$\frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right)^2} - 3$
Minimum (i_min)	The minimum intensity value in the region surrounded by the contour
Maximum (i_max)	The maximum intensity value in the region surrounded by the contour

En la tabla 3 se muestra un conjunto de descriptores de textura calculados apartir de la matriz de co-ocurrencia de nivel de gris relacionados con el cuadro delimitador del contorno de la lesión identificada por los radiólogos.

En la tabla 4 se muestra un conjunto de descriptores de forma y localización de la lesión identificada por el radiólogo.

Tabla 3. Conjunto de descriptores de textura.

Feature	Description
Energy (t_energ)	$\sum_{i=1}^L \sum_{j=1}^L p(i, j)^2$ with L being the number of grey-levels, and p being the grey-level co-occurrence matrix and, thus, $p(i, j)$ is the probability of pixels with grey-level i occur together to pixels with grey-level j .
Contrast (t_contr)	$\sum_i \sum_j (i - j)^2 p(i, j)$
Correlation (t_corr)	$\frac{\sum_i \sum_j (ij) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}$ with μ_x, μ_y, σ_x and σ_y being the means and standard deviations of p_x and p_y , the partial probability density functions.
Sum of Squares: Variance (t_sosvh)	$\sum_i \sum_j (i - \mu)^2 p(i, j)$ with μ being the mean of $p(i, j)$ for all i and j .
Homogeneity (t_homo)	$\sum_i \sum_j \frac{1}{1 + (i - j)^2} p(i, j)$
Sum Average (t_savgh)	$\sum_{i=2}^{2L} i p_{x+y}(i)$ with $p_{x+y}(i)$ being the probability of the co-occurrence matrix coordinates summing $i = x + y$
Sum Entropy (t_senth)	$se = - \sum_{i=2}^{2L} p_{x+y}(i) \log(p_{x+y}(i))$
Sum Variance (t_svarh)	$\sum_{i=2}^{2L} (i - se)^2 p_{x+y}(i)$
Entropy (t_entro)	$-\sum_{i=1}^L \sum_{j=1}^L p(i, j) \log(p(i, j))$
Difference Variance (t_dvarh)	$\sum_{i=0}^{L-1} i^2 p_{x-y}(i)$ with $p_{x-y}(i)$ being the probability of the co-occurrence matrix coordinates subtracting $i = x - y $
Difference Entropy (t_denth)	$-\sum_{i=0}^{L-1} p_{x-y}(i) \log(p_{x-y}(i))$
Information Measure of Correlation 1 (t_inf1h)	$\frac{-\sum_{i=1}^L \sum_{j=1}^L p(i, j) \log(p(i, j)) + \sum_{i=1}^L \sum_{j=1}^L p(i, j) \log(p_x(i) p_y(j))}{\max\left(\sum_{i=1}^L p_x(i) \log(p_x(i)), \sum_{i=1}^L p_y(i) \log(p_y(i))\right)}$
Information Measure of Correlation 2 (t_inf2h)	$\sqrt{1 - \exp\left(2\left(\sum_{i=1}^L \sum_{j=1}^L p_x(i) p_y(j) \log(p_x(i) p_y(j)) - \sum_{i=1}^L \sum_{j=1}^L p(i, j) \log(p(i, j))\right)\right)}$


Tabla 4. Conjunto de descriptores de forma y localización.

Feature	Description
Area (s_area)	$area = O $ with O being the set of pixels that belong to the segmented lesion
Perimeter (s_perimeter)	$perimeter = length(E)$ with $E \subset O$ being the edge pixels
Center of mass (s_x_center_mass, s_y_center_mass)	Normalized coordinates of the center of mass of O
Circularity (s_circularity)	$4\pi \frac{area}{perimeter^2}$
Elongation (s_elongation)	$elongation = \frac{m}{M}$ with m being the minor axis and M the major axis of the ellipse that has the same normalized second central moments as the region surrounded by the contour
Form (s_form)	$\frac{perimeter \times elongation}{8 \times area}$
Solidity (s_solidity)	$\frac{area}{ H }$ with H being the set of pixels that belong to the convex hull of the segmented region
Extent (s_extent)	$\frac{area}{ B }$ with B being the set of pixels that belong to the bounding box of the segmented region

Como forma de obtener un modelo de clasificación que permitiría distinguir entre lesiones malignas y lesiones benignas se construyó una red neuronal de propagación hacia atrás la cual tomaron como datos de entrada a la red neuronal los conjuntos de descriptores de intensidad, textura, forma y localización.

La red neuronal se formó por la capa de entrada con las 28 características, con 2 capas ocultas, la primera de 5 y la segunda de 3 y la capa de salida binaria con la clasificación de cáncer maligno o benigno, como se muestra en la imagen 2.

Imagen 2.- Red Neuronal



La red neuronal se probó con los datos normalizados y sin normalizar, se realizó validación cruzada con datos para entrenamiento 75% y para prueba 25% y se corrieron diferentes configuraciones de la(s) capa(s) oculta(s).

3.- RESULTADOS

Como se puede ver en la Imagen 2 y 3 utilizando los datos sin normalizados se obtuvo un $AUC = 0.9797$ y $AUC = 0.8509$ para train y test respectivamente, y en las imágenes 4 y 5 con datos normalizados se obtuvo un $AUC = 0.7435$ y $AUC = 0.7078$ para train y test respectivamente.

Imagen 2.- Train – Datos sin normalización




Imagen 3.- Test – Datos sin normalización




Imagen 4.- Train – Datos normalizados





Imagen 5.- Test – Datos normalizados



En la imagen 6 se muestra el resultado de la tabla de confusión con los datos de los casos benignos y malignos acertados por el algoritmo, así como los falsos negativos y positivos.




Imagen 6.- Calidad de diagnóstico.

En la tabla 5 se muestra el área bajo la curva resultante de modificar la cantidad de neuronas en las capas ocultas para poder comprobar que tanto afecta la distribución de la red neuronal.

Tabla 5.- Capas Ocultas

1ra oculta	2da oculta	Train - AUC	Test - AUC
1	1	0.9608	0.8765
2	1	0.9605	0.8971
3	1	0.9746	0.8477
4	1	0.9894	0.8642
5	1	1.0000	0.8354
6	1	0.9915	0.8601
7	1	0.9936	0.8642
8	1	0.9944	0.8354
1	2	0.9753	0.8519
2	2	0.9892	0.8333
3	2	0.9852	0.8765
4	2	0.9693	0.8642
5	2	1.0000	0.7613
6	2	1.0000	0.7860
7	2	0.9703	0.8889
8	2	1.0000	0.8066
1	3	0.9718	0.8765
2	3	0.9848	0.8642
3	3	0.9552	0.8848
4	3	1.0000	0.8189
5	3	0.9799	0.8724
6	3	1.0000	0.7860
7	3	1.0000	0.8107
8	3	1.0000	0.8148
1	4	0.9594	0.8477
2	4	0.9693	0.8580
3	4	0.9929	0.8724
4	4	0.9809	0.8807
5	4	0.9908	0.8025
6	4	1.0000	0.7407
7	4	1.0000	0.8560
8	4	1.0000	0.8272
1	5	0.9746	0.8436
2	5	0.9926	0.8189
3	5	0.9898	0.8519
4	5	1.0000	0.8148
5	5	0.9936	0.8642
6	5	1.0000	0.8560
7	5	1.0000	0.7860
8	5	1.0000	0.8519

4.- DISCUSION

Mediante el uso de una red neuronal de propagación hacia atrás para la clasificación de pacientes con alto y bajo riesgo de padecer cáncer de mama con los datos sin normalizar y utilizando todas las características con un área bajo la curva de 0.9018. Los resultados de este trabajo se limitaron a un escáner de la base de datos pública BCDR y como se demostró en la sección de resultados en la tabla 5, sin importar el tipo de arquitectura de la red neuronal se obtienen resultados similares y con un excelente desempeño.

5.- CONCLUSIONES

En esta investigación se demostró que se puede clasificar un paciente con riesgo de padecer cáncer de mama con la extracción de características de las mamografías y la clasificación que proporcionan las redes neuronales y en este caso con la propagación hacia atrás.

Acknowledgments

Este trabajo fue apoyado económicamente por beca CONACYT con el número de apoyo 439502 y número de registro becario 601498 para el grado de MAESTRÍA.

REFERENCIAS

- [1] N. Jazdi, "Cyber physical systems in the context of Industry 4.0," in *Automation, Quality and Testing, Robotics, 2014 IEEE International Conference on*, 2014, pp. 1-4: IEEE.
- [2] H.-D. Cheng, X. Cai, X. Chen, L. Hu, and X. Lou, "Computer-aided detection and classification of microcalcifications in mammograms: a survey," *Pattern recognition*, vol. 36, no. 12, pp. 2967-2991, 2003.
- [3] R. M. Rangayyan, F. J. Ayres, and J. L. Desautels, "A review of computer-aided diagnosis of breast cancer: Toward the detection of subtle signs," *Journal of the Franklin Institute*, vol. 344, no. 3, pp. 312-348, 2007.
- [4] L. H. Eadie, P. Taylor, and A. P. Gibson, "A systematic review of computer-assisted diagnosis in diagnostic cancer imaging," *European journal of radiology*, vol. 81, no. 1, pp. e70-e76, 2012.
- [5] N. Andrew, "Machine Learning," in *Machine Learning*, C. Stanford University, Ed., ed: Coursera, 2016.
- [6] D. C. Moura and M. A. G. López, "An evaluation of image descriptors combined with clinical data for breast cancer diagnosis," *International journal of computer assisted radiology and surgery*, vol. 8, no. 4, pp. 561-574, 2013.
- [7] M. A. G. López, N. Posada, D. C. Moura, R. Polln, J. M. F. Valiente, and C. S. Ortega, "BCDR: a breast cancer digital repository," in *15th International Conference on Experimental Mechanics*, 2012.

Breast cancer tumor classification using LASSO method selection approach

José María Celaya Padilla¹⁻⁴, Jorge Armando Ortiz Murillo¹⁻⁴, María Del Rosario Martínez Blanco¹⁻⁴, Luis Octavio Solís Sánchez¹⁻⁴, Rodrigo Castañeda Miranda¹⁻⁴, Idalia Garza Veloz¹⁻³, Margarita Martínez Fierro¹⁻³, José Manuel Ortiz Rodríguez^{1-4,*}

Universidad Autónoma de Zacatecas, Av. Ramón López Velarde 801, Col. Centro 98000 Zacatecas, México:

¹ Centro de Investigación e Innovación Tecnológica Industrial (CIITI)

² Laboratorio de Innovación y Desarrollo Tecnológico en Inteligencia Artificial, (LIDTIA)

³ Laboratorio de Bioinformática

⁴ Unidad Académica de Ingeniería Eléctrica (UAIE)

*Corresponding: morvymm@yahoo.com.mx

Abstract

Breast cancer is one of the leading causes of deaths worldwide among women. Early tumor detection is key in reducing breast cancer deaths and screening mammography is the widest available method for early detection. Mammography is the most common and effective breast cancer screening test. However, the rate of positive findings is very low, making the radiologic interpretation monotonous and biased toward errors. In an attempt to alleviate radiological workload, this work presents a computer-aided diagnosis (CADx) method aimed to automatically classify tumor lesions into malign or benign as a means to a second opinion. The CADx method, extracts image features, and classifies the screening mammogram abnormality into one of two categories: subject at risk of having malignant tumor (malign), and healthy subject (benign). In this study, 143 abnormal segmentations (57 malign and 86 benign) from the Breast Cancer Digital Repository (BCDR) public database were used to train and evaluate the CADx system. Percentile-rank (p-rank) was used to standardize the data. Using the LASSO feature selection methodology, the model achieved a Leave-one-out cross-validation area under the receiver operating characteristic curve (AUC) of 0.950. The proposed method has the potential to rank abnormal lesions with high probability of malignant findings aiding in the detection of potential malign cases as a second opinion to the radiologist.

Keywords: Breast cancer detection, LASSO, malign tumor, data mining.

1.- INTRODUCTION

There is no limit of Breast cancer is one of the leading causes of woman's death all over the world (Nishikawa, 2007) . In developing countries breast cancer is an important public health issue, where demographic and epidemiological transition is not matched with public screening and treatment programs (Knaul et al.). One of the most effective modality for detecting the early-stage breast cancer is screening mammography, which is an inexpensive tool for classifying abnormalities such as calcifications and masses, as well as subtle signs, like architectural distortion and bilateral asymmetry, and is the most effective method for detection of breast cancer before it becomes clinically palpable (Ng & Mutarak). Screening mammography is a standardized study in which craniocaudal (CC) and mediolateral oblique (MLO) views are acquired from each breast and inspected by a specialized radiologist. However, detection of abnormalities in screening mammography is a repetitive and fatiguing task, which affects the performance of the radiologist over a workday. In a normal screening setting, only 0.3% to 0.4%, of the inspections are cancerous, resulting in radiologists failing to detect 10% - 30% of those (Sampat, Markey, Bovik, & others). In recent years there has been a great effort in research to develop computer-aided detection or diagnosis (CAD) systems that use computer technologies to assist radiologists in their decisions were a high number of studies must be examined. Different approaches have been proposed for detection and characterization of calcifications. (H.-D. Cheng, Cai, Chen, Hu, & Lou) and (Sampat et al.) summarize the different methods used and their performance.

In this work we propose a methodology to detect and classify lesions present in a mammogram for breast cancer that can be used to profile screening mammography patients. The methodology takes the set of mammograms from each patient in a database, using the ROI delimited by the radiologist extracts a set of features from these images. Using a multivariate feature selection algorithm, we were able to identify a set of features with high predictive value. The selected features were then used to distinguish between benign and malign tumors. This procedure can be used as a biomarker as a second opinion to the radiologist, this paper is organized as follows: In Section II we describe the proposed

methodology in detail. Section III contains the obtained results from the methodology. The results are discussed in section IV and V.

2.- MATERIALS AND METHODS

In this research we propose a methodology to aid the radiologist by analyzing the suspicious lesions that may indicate signs of breast cancer. The proposed methodology extracts a series of features to characterize the lesion, then using advanced machine learning techniques, a model to classify said lesions is obtained. The methodology overview is presented in Figure 1, briefly, first a subject's mammogram is presented to the radiologist, the radiologist then adjusts the contrast and other values to better visualize the possible abnormalities, then if any, the Region of Interest (ROI) is segmented. Afterwards, feature extraction is performed in order to characterize the abnormality. Finally, a robust Machine Learning technique (LASSO) is performed in order to find the best subset of features capable of distinguishing malign from benign lesions.




Figure 1.- Methodology overview.

2.1.- Materials

In this research a public available dataset Breast Cancer Digital Repository (BCDR) (López et al., 2012) was used. This dataset is composed by 1734 patients with mammography and ultrasound images, clinical history, lesion segmentation and selected pre-computed image-based descriptors. Patient cases are BIRADS classified and annotated by specialized radiologists. From the above dataset, a subset of 143 abnormal ROI segmentations (57 malign and 86 benign), a total of 28 features were extracted : 8 features were extracted from the intensity descriptors computed directly from the grey-levels of the pixels inside

the lesion’s contour identified by the radiologists, 12 texture features were computed from the Grey-level co-occurrence matrix related to the bounding box of lesion’s contour, and finally 8 features related to the shape and location descriptors of the lesion, the full description of said features is presented in Table 1 and Table2. The dataset contains two possible outcome classification “Benign” or “Malign” labeled by the specialized radiologist.

Table 1. Texture features.

Feature	Description
Energy (t_energ)	$\sum_{i=1}^L \sum_{j=1}^L p(i, j)^2$ with L being the number of grey-levels, and p being the grey-level co-occurrence matrix and, thus, $p(i, j)$ is the probability of pixels with grey level i occur together to pixels with grey level j .
Contrast (t_contr)	$\sum_i \sum_j (i - j)^2 p(i, j)$
Correlation (t_corr)	

	$\frac{\sum_i \sum_j (ij) p(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}$ <p>with μ_x, μ_y, σ_x and σ_y being the means and standard deviations of p_x and p_y, the partial probability density functions.</p>
Sum of Squares: Variance (t_snsvh)	$\sum_i \sum_j (i - \mu)^2 p(i, j)$ <p>with μ being the mean of $p(i, j)$ for all i and j.</p>
Homogeneity (t_homc)	$\sum_i \sum_j \frac{1}{1 + (i - j)^2} p(i, j)$
Sum Average (t_savgh)	$\sum_{i=2}^{2L} i p_{x+y}(i)$ <p>with $p_{x+y}(i)$ being the probability of the co-occurrence matrix coordinates summing $i = x + y$</p>
Sum Entropy (t_senth)	$se = - \sum_{i=2}^{2L} p_{x+y}(i) \log(p_{x+y}(i))$
Sum Variance (t_svarh)	$\sum_{i=2}^{2L} (i - se)^2 p_{x+y}(i)$
Entropy (t_entro)	$- \sum_{i=1}^L \sum_{j=1}^L p(i, j) \log(p(i, j))$
Difference Variance (t_dvarh)	$\sum_{i=0}^{L-1} i^2 p_{x-y}(i)$ <p>with $p_{x-y}(i)$ being the probability of the co-occurrence matrix coordinates subtracting $i = x - y$</p>
Difference Entropy (t_denth)	$- \sum_{i=0}^{L-1} p_{x-y}(i) \log(p_{x-y}(i))$
Information Measure of Correlation 1 (t_inf1h)	$\frac{- \sum_{i=1}^L \sum_{j=1}^L p(i, j) \log(p(i, j)) + \sum_{i=1}^L p_x(i) \log(p_x(i)) + \sum_{j=1}^L p_y(j) \log(p_y(j))}{\max \left(\sum_{i=1}^L p_x(i) \log(p_x(i)), \sum_{j=1}^L p_y(j) \log(p_y(j)) \right)}$
Information Measure of Correlation 2 (t_inf2h)	$\sqrt{1 - \exp \left(2 \left(\sum_{i=1}^L \sum_{j=1}^L p_x(i) p_y(j) \log(p_x(i) p_y(j)) - \sum_{i=1}^L p_x(i) \log(p_x(i)) - \sum_{j=1}^L p_y(j) \log(p_y(j)) \right) \right)}$

Table 2. Shape and localization features.

Feature	Description
Area (s_area)	$area = O $ with O being the set of pixels that belong to the segmented lesion
Perimeter (s_perimeter)	$perimeter = length(E)$ with $E \subset O$ being the edge pixels
Center of mass (s_x_center_mass, s_y_center_mass)	Normalized coordinates of the center of mass of O
Circularity (s_circularity)	$4\pi \frac{area}{perimeter^2}$
Elongation (s_elongation)	$elongation = \frac{m}{M}$ with m being the minor axis and M the major axis of the ellipse that has the same normalized second central moments as the region surrounded by the contour
Form (s_form)	$\frac{perimeter \times elongation}{8 \times area}$
Solidity (s_solidity)	$\frac{area}{ H }$ with H being the set of pixels that belong to the convex hull of the segmented region
Extent (s_extent)	$\frac{area}{ B }$ with B being the set of pixels that belong to the bounding box of the segmented region

2.1.- Methods

In order to select the most accurate and compact set of features, a multivariate search strategy was performed using Least Absolute Shrinkage and Selection Operator (LASSO) [38], LASSO is a shrinkage and selection method that minimizes the usual sum of squared errors which penalizes the regression coefficients Equation 1. The multivariate search was performed using a using leave-one-subject-out cross validation (LOOCV) strategy [39], training the models for every split using $N-1$ subjects and testing in the left out subject.

$$\hat{\beta}^{lasso} = argmin \sum_{i=1}^N (y_i - \beta_0 - \sum_{j=1}^p x_{ij}\beta_j)^2 \text{ subject to: } \sum_{j=1}^p |\beta_j| \leq t \quad (1)$$

3.- RESULTS

A 0.9508 Area Under the Receiver Operation Catachrestic (AUC) was achieved using the final model obtained using the LASSO methodology. On Figure 2 the ROC curve is presented for the final model using the LOOCV.




Figure 2.- Model performance using LOOCV, AUC = 0.9508.

From the 28 features pool, the multivariate feature selection methodology LASSO was able to reduce the number of features need down to only nine features. The final model included a combination of features extracted from the intensity descriptors, texture features and features related to the shape and location descriptors of the lesion, summarize the performance achieved by each group of feature. The final model with all the statistic information is shown in Table 3.

Table 3.- Final model.

Feature	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-0.1755	2.6107	-0.067	0.946413
i_skewness	-2.3165	1.6345	-1.417	0.156424
s_perimeter	5.2351	2.3877	2.193	0.028343*
s_x_center_mass	-3.0137	1.3466	-2.238	0.025223*
s_elongation	2.8573	1.4871	1.921	0.054681^
s_solidity	-6.3953	1.7068	-3.747	0.000179*
t_energ	-0.9427	1.418	-0.665	0.506176
t_corr	-2.7176	5.5612	-0.489	0.625079
t_sosvh	0.5457	1.3994	0.39	0.696571
t_inf2h	5.0663	4.938	1.026	0.304903

*Statistical significance <0.05, ^marginal statistical significance <0.05

The confusion matrix of the final model is presented in the Figure 3, the model achieved an accuracy of 0.8462 with 95% CI (0.7764, 0.901), and a McNemar's Test P-Value of 5.104e-05.




Figure 3.- Confusion matrix.

4.- DISCUSSION

A feature selection strategy was used to find a multivariate model to classify benign from the malignant lesions on the breast images. The methodology demonstrates that image characterization is a good approach to identify patients with lesions that can be cancer-related. The automatically generated Logistic regression classifier included features of different groups, therefore, texture analyses, and signal properties could add discriminant information.

The LASSO model selection strategy yields reproducible models of healthy versus malignant abnormal lesion detection with a LOOCV AUC of 0.9508. Furthermore, the detailed analysis of the ROC curve may give us indications of key triaging points for prioritizing the mammogram reading. Priority triaging may have real practical usage in regions where expert radiological resources are scarce or costly.

The results of the work cannot yet be generalized and the presented findings are limited to a single scanner of the public BCDR dataset. Even having these strong limitations, we believe that the methodology can be replicated with full-field digital mammography and with newer advanced technologies like tomosynthesis.

5.- CONCLUSIONS

This research was able to show that healthy lesions, and subjects with malign lesions can accurately be classified through models generated via accurate mammography feature extraction a feature selection methodology. The methodology demonstrated that abnormal lesions can be automated classified regardless of the size, form and shape. The achieved performance of the system has the potential to be used as a second opinion, and may be used to reduce the unnecessary biopsies.

Future work can include the usage of other image transforms to obtain further information, this methodology is intended to be used to help the radiologist as a second opinion, and to reduce the load of work if the models are used as a screening biomarker that accurately classify which subjects have a malign or benign lesion, therefore, reducing the unnecessary biopsies.

Acknowledgments

This work was partially supported by Fondo Sectorial de Investigación para la Educación under contract 241771, Fondos Mixtos SEP-CONACYT under contract ZAC-C03-2015-26357-4, and PROSOFT under contract 201513723. The first author wants to thank CONACYT for the post-doctoral scholarship number 24296.

REFERENCES

- Bovis, K., & Singh, S. (2000). *Detection of masses in mammograms using texture features*. Paper presented at the Pattern Recognition, 2000. Proceedings. 15th International Conference on.
- Cheng, H., Shi, X., Min, R., Hu, L., Cai, X., & Du, H. (2006). Approaches for automated detection and classification of masses in mammograms. *Pattern recognition*, 39(4), 646-668.
- Cheng, H.-D., Cai, X., Chen, X., Hu, L., & Lou, X. (2003). Computer-aided detection and classification of microcalcifications in mammograms: a survey. *Pattern recognition*, 36(12), 2967-2991.
- Knaul, F. M., Nigenda, G., Lozano, R., Arreola-Ornelas, H., Langer, A., & Frenk, J. (2009). Cancer de mama en Mexico: una prioridad apremiante. *Salud Publica Mex*, 51(s2).

- López, M. A. G., de Posada, N. G., Moura, D. C., Pollán, R. R., Valiente, J. M. F., Ortega, C. S., . . . Loureiro10, J. P. (2012). *BCDR: A BREAST CANCER DIGITAL REPOSITORY*. Paper presented at the 15th International Conference on Experimental Mechanics.
- Mendez, A. J., Tahoces, P. G., Lado, M. i., a J, Souto, M., & Vidal, J. J. (1998). Computer-aided diagnosis: Automatic detection of malignant masses in digitized mammograms. *Medical Physics*, 25, 957.
- Ng, K., & Muttarak, M. (2003). Advances in mammography have improved early detection of breast cancer. *Honk Kong College or radiologist*, 6, 126-131.
- Nishikawa, R. M. (2007). Current status and future directions of computer-aided diagnosis in mammography. *Computerized Medical Imaging and Graphics*, 31(4), 224-235.
- Sampat, M. P., Markey, M. K., Bovik, A. C., & others. (2005). Computer-aided detection and diagnosis in mammography. *Handbook of image and video processing*, 2(1), 1195-1217.
- Yin FF, G. M., Vyborny CJ. (1993). Comparison of bilateral-subtraction and single-image processing techniques in the computerized detection of mammographic masses. *Investigative Radiology*, 28(6), 473-481.

Optimización de la arquitectura de una red neuronal en espectrometría de neutrones para reducir el número de esferas Bonner

Ana Alicia León-Pérez^{1-3*}, Ma. del Rosario Martínez-Blanco¹⁻³, Cruz Felipe Hernández-Pérez¹⁻³, J. Guadalupe Espinoza-García¹⁻³, Víctor Hugo Castañeda-Miranda¹⁻³, Luis Octavio Solís-Sánchez¹⁻³, Rodrigo Castañeda-Miranda¹⁻³, Hector Rene Vega-Carrillo⁴, Roberto Méndez Villafañe⁵, Eduardo Gallego⁶, Marco Aurelio de Sousa Lacerda⁷ y José Manuel Ortiz-Rodríguez¹⁻³

Universidad Autónoma de Zacatecas, Av. Ramón López Velarde 801, Col. Centro 98000, Zacatecas, México.

¹ Centro de Investigación e Innovación Tecnológica Industrial (CIITI)

² Laboratorio de Innovación y Desarrollo Tecnológico en Inteligencia Artificial (LIDTIA)

³ Unidad Académica de Ingeniería Eléctrica

⁴ Unidad Académica de Estudios Nucleares (UAEN)

⁵ Laboratorio de Patrones Neutrónicos del Departamento de Metrología de Radiaciones Ionizantes del Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas (CIEMAT), Avda. Complutense, 22, 28040, Madrid, España

⁶ Departamento de Ingeniería Nuclear de la Universidad Politécnica de Madrid (DIN-UPM), ETSI Industriales, C. José Gutiérrez Abascal, 2, 28006, Madrid España

⁷ Centro de Investigación de Tecnología Nuclear de la Comisión Nacional de Energía Nuclear (CDTN-CNEN), Av. Presidente Antonio Carlos, 6627, Pampulha, CEP: 31270-901, Belo Horizonte, MG, Brazil

RESUMEN

La espectrometría de neutrones es un proceso experimental para determinar la distribución de energía denominado Espectro. Dentro de los métodos disponibles para la espectrometría de neutrones se puede mencionar el Sistema Espectrométrico de Esferas Bonner como uno de los más utilizados, compuesto por un detector colocado en el centro de un conjunto de esferas de polietileno, cuyos diámetros varían desde 2 hasta 18 pulgadas, sin embargo posee algunas desventajas como son los largos periodos de tiempo para realizar las mediciones,

el peso, y el número de esferas que varían según el sistema. A partir de esto se proponen métodos alternativos como Redes Neuronales Artificiales. Para este proyecto se hizo uso de Redes neuronales de propagación inversa con la Metodología de diseño robusto de redes neuronales artificiales (MDRRNA), con la ayuda de una herramienta computacional que maximiza el rendimiento, haciendo que el tiempo empleado para los entrenamientos de la red sea el menor posible y así obtener los arreglos ortogonales rápidamente para determinar la mejor topología de red. Se usaron las tasas de conteo de un sistema Espectrométrico con 7 esferas, 2 esferas y 1 esfera de 5 y 8 pulgadas. Usando esta metodología se buscó reducir el trabajo empleado como en el sistema Espectrométrico conformado por un número mayor de esferas, ya que al ingresar menos datos en las tasas de conteo para obtener los espectros con 60 niveles de energía se ahorra tiempo y espacio, pues al tener un menor número de esferas su portabilidad es más fácil para desplazarse de un lugar a otro, para esto se realizaron varios experimentos con diferentes errores hasta llegar al error óptimo para que la topología de la red fuera la apropiada y encontrar los mejores parámetros de diseño, también se hizo uso de un software estadístico JMP para obtener las mejores topologías y así volver a entrenar obteniendo sus mejores y peores espectros y de esta manera determinar si es posible la reducción.

Palabras clave: Espectrometría de neutrones; esferas Bonner, redes neuronales artificiales, optimización.

1.- INTRODUCCIÓN

Debido a la ausencia de carga de los neutrones son partículas difíciles de detectar, además de poseer un poder de penetración mayor que las partículas cargadas y la radiación electromagnética, dándole la posibilidad de interactuar con la materia diferente a otras partículas, [Reyes-Haro; Ortiz-Rodríguez & Vega Carrillo, 2012] estas interacciones tienen una baja probabilidad y producen una pequeñísima pérdida de energía lo cual significa que se necesitan muchas colisiones en diferentes materiales de gran espesor para que la energía del neutrón disminuya. [Cember 1996]

Desde el descubrimiento del neutrón en 1932 por Chadwick ha sido de gran importancia pues ha brindado las bases para nuevos descubrimientos, dentro de los cuales se puede mencionar la espectrometría de neutrones que es una técnica experimental para determinar por medio de neutrones la intensidad de un campo de radiación con respecto a la energía, a lo cual se le conoce como “espectro” [Del Hoyo-Becerra 2013]

Debido a que los neutrones no son desviados por un campo eléctrico o magnético y también porque producen una ionización apreciable, se deben emplear métodos indirectos para detectarlos y medir su energía [Martínez-Blanco, Ortiz-Rodríguez & Vega-Carrillo, 2006]. La medición y particularmente la determinación de espectros de neutrones no es una tarea fácil, debido a las características que el neutrón presenta, pero para resolver este problema existen detectores e instrumentos que permiten determinar los espectros de los neutrones, uno de los métodos para conocer el espectro de neutrones en los campos de radiación a los que los individuos se ven expuestos es el uso del Sistema Espectrométrico de Esferas Bonner (SEEB). [Ortiz Rodríguez 2005]

1.1 Sistema Espectrométrico de Esferas Bonner (SEEB)

El espectrómetro de neutrones multiesferas también llamado Sistema Espectrométrico de Esferas Bonner fue descrito por primera vez en 1960 por Bramblett, Erwing y Bonner [Bakali 2001] este sistema se basa en el uso de un detector envuelto con esferas de

diferentes diámetros de polietileno, al incidir los neutrones sobre la esfera se convierten en partículas secundarias, estas partículas se transportan e interactúan con los núcleos perdiendo energía y alcanzando al detector, el cual está ubicado en el centro de la esfera. [Reyes-Alfaro 2014] En el detector se produce una reacción nuclear que genera un pulso que es amplificado y acumulado, de acuerdo a su altura, en un analizador multicanal. Al aumentar el diámetro de la esfera aumenta la sensibilidad del sistema hacia las energías altas y de esta manera es posible llevar a cabo la espectrometría de neutrones. [Martínez-Blanco 2006]

Algunas de las desventajas del SEEB son las siguientes:

- El peso del mismo debido al número de esferas y diferentes tamaños que posee.
- Los largos periodos de tiempo empleados para realizar las mediciones.
- La baja resolución del sistema
- La necesidad de un código para la reconstrucción y usuario experimentado para la manipulación del código.

A partir de esto se proponen métodos alternativos como los son las Redes Neuronales Artificiales, para este trabajo se utilizó la Metodología de diseño robusto de redes neuronales artificiales (MDRRNA) para este caso se usó la Red neuronal de propagación inversa [Ortiz-Rodríguez *et al.*, 2005; Ortiz-Rodríguez 2005]

El objetivo de este trabajo es determinar si es posible reducir el número de esferas Bonner por medio de la optimización de la arquitectura de una red neuronal en espectrometría de neutrones, mediante la Metodología de Diseño Robusto de Redes Neuronales Artificiales (MDRRNA), buscando reducir el trabajo empleado como es el caso del sistema Espectrométrico de esferas Bonner conformado por un número mayor de esferas.

2.- MATERIALES Y MÉTODOS

En este trabajo se hizo uso de la metodología de diseño Robusto de Redes Neuronales Artificiales (que se muestra en la figura siguiente) para determinar los valores óptimos de las variables de diseño una red neuronal que sea capaz de reconstruir espectros de neutrones, dicha metodología está basada en la metodología de Taguchi, que está compuesto por varias etapas que son: planeación, experimentación, análisis y confirmación [Unal & Dean, 1991], esto se realizó para cuatro casos los cuales incluyen un diferente número de esferas y tamaños, 7 esferas, 2 esferas, 1 esfera de 8 pulgadas y 1 de 5 pulgadas.



Figura 1.- Metodología de Diseño Robusto de Redes Neuronales Artificiales.

2.1 Planeación

Dentro de la etapa de planeación se hace la búsqueda de variables de diseño, que son las variables controlables que se encuentran dentro de la región de búsqueda, la cual se muestra en la siguiente figura:

Niveles de las variables de diseño			
Var. diseño	Nivel 1	Nivel 2	Nivel 3
A			
B			
C			
D			

Figura 2.- Variables de diseño y sus niveles.

Donde la parte de las variables representadas con A, B, C y D son los parámetros del número de neuronas por capas, tasa de aprendizaje y momento.

Niveles de las variables de ruido		
Vars. ruido	Nivel 1	Nivel 2
U	Conjunto 1	Conjunto 2
V	E:P	E:P
W	Entren1-Prueba1	Entren2-Prueba2

Figura 3.- Variables de ruido y sus niveles

En la figura anterior se muestran las variables de ruido, la variable U representa los conjuntos de inicialización de pesos, en la V la relación tamaño de datos Entrenamientos-prueba y la W la solución del conjunto Entrenamiento-Prueba.

2.2 Experimentación

En esta fase se hace la optimización de la arquitectura de red mediante la herramienta principal de la hoja de Excel siguiendo la metodología de diseño Robusto, en las cuales se hacen las combinaciones correspondientes utilizando las tablas de las variables de diseño y de ruido, para el llenado de los arreglos ortogonales (desempeños) se hizo uso de una herramienta de computo en el entorno de MATLAB, para obtener más rápido los desempeños de las redes entrenadas, reduciendo el tiempo empleado en esta actividad y obteniendo los arreglos ortogonales para cada caso, en esta etapa también se experimentó con la búsqueda del error mínimo con el cual funcionara mejor la red.

R17					G1	G2	G3	G4	Media de Y	Relación S/R
	Neuronas en capa 1	Neuronas en capa 2	Tasa de aprendizaje	Momento	U=1	U=1	U=2	U=2		
					V=1	V=2	V=1	V=2		
					W=2	W=1	W=1	W=2		
Exp-1111	1	1	1	1						
Exp-1222	1	2	2	2						
Exp-1333	1	3	3	3						
Exp-2123	2	1	2	3						
Exp-2231	2	2	3	1						
Exp-2312	2	3	1	3						
Exp-3132	3	1	3	2						
Exp-3213	3	2	1	3						
Exp-3321	3	3	2	1						

Figura 4.- Formato para determinación de parámetros

Para el entrenamiento de las Redes se utilizaron los espectros de neutrones publicado por la Agencia Internacional de Energía Atómica, donde se usa una relación de tamaño (entrenamiento-prueba) de datos de entrenamiento prueba, tomando como entrada las tasas de conteo correspondientes a las diferentes esferas con diferentes dimensiones del SEEB y a la salida los 60 niveles de energía.

2.3 Análisis

Después de obtener los arreglos para las diferentes esferas nos pasamos al análisis estadístico se analizan las relaciones señal-ruido por medio de la técnica del análisis de la

varianza, para determinar los efectos significativos, y los niveles óptimos de las variables de diseño mediante el programa JMP y así obtener las posibles mejores topologías.

2.4 Confirmación

Ya que se obtienen las posibles mejores topologías para cada caso de esfera, se vuelven a entrenar con los mismos datos de entrenamiento de prueba que sería con un 80% para el entrenamiento y 20% de prueba, utilizando las mismas columnas de entrenamiento y prueba de cualquiera de los casos.

Se hicieron cuatro experimentos para cada caso (diferente número de esferas), se obtuvieron las gráficas de χ^2 (χ^2) y correlación (R), a partir de esto se hizo la clasificación de las mejores topologías, de estos resultados se compararon los mejores y peores casos en sus espectros para verificar que funcionan de igual manera para cualquier número de esferas.

3.- RESULTADOS

Utilizando la metodología de diseño robusto de redes neuronales artificiales se aplicaron cada una de sus etapas y se obtuvieron los siguientes resultados:

3.1 Planeación

Dentro de la etapa de planeación se determinaron las variables de diseño y ruido, las cuales se muestran a continuación:

Niveles de las variables de diseño			
Var. diseño	Nivel 1	Nivel 2	Nivel 3
A	6	8	10
B	0	8	10
C	0.001	0.1	0.3
D	0.001	0.05	0.1

Figura 5.- Variables de diseño

Niveles de las variables de ruido		
Vars. ruido	Nivel 1	Nivel 2
U	Conjunto 1	Conjunto 2
V	6:4	8:2
W	Entren1-Prueba1	Entren2-Prueba2

Figura 6.- Variables de ruido

3.2 Experimentación

A continuación se muestra uno de los resultados (para el caso de 7 esferas) un arreglo ortogonal, llevado a cabo en la etapa de experimentación también se encontró que el error más óptimo fue $1e-4$ para cada uno de los casos.

R17	Neuronas en capa 1	Neuronas en capa 2	Tasa de aprendizaje	Momento	G1	G2	G3	G4
					U=1	U=1	U=2	U=2
					V=1	V=2	V=1	V=2
					W=2	W=1	W=1	W=2
Exp-1111	6	0	0.001	0.001	0.000298656	0.000301932	0.000398781	0.000287752
Exp-1222	6	8	0.1	0.05	0.000321691	0.000298608	0.000309831	0.000266297
Exp-1333	6	10	0.3	0.1	0.00035867	0.000275744	0.000326509	0.000296514
Exp-2123	8	0	0.1	0.1	0.000276674	0.000207462	0.000310295	0.000309987
Exp-2231	8	8	0.3	0.001	0.000352625	0.000429237	0.000328881	0.000389557
Exp-2312	8	10	0.001	0.05	0.000341382	0.00015683	0.000325344	0.000302847
Exp-3132	10	0	0.3	0.05	0.000277241	0.000197384	0.000331787	0.000302436
Exp-3213	10	8	0.001	0.1	0.000407251	0.000279461	0.000376102	0.000387481
Exp-3321	10	10	0.1	0.001	0.00030705	0.0004145	0.000380687	0.000257836

Figura 7 Ejemplo de la obtención de parámetros

3.3 Análisis

Después de obtener los arreglos para los distintos números y tamaños de esferas nos pasamos al análisis estadístico JMP donde se obtienen las posibles mejores topologías de red, a continuación se muestra un ejemplo de obtención de una de las topologías, donde se obtienen varios perfiles normal, deseado y maximizado, donde solo se tomaron en cuenta el normal y maximizada pues la normal y deseada son las mismas.




Figura 8.- Ejemplo en obtencion de la mejor topologia para el caso de 7 esferas normal




Figura 9.- Ejemplo en obtencion de la mejor topologia para el caso de 7 esferas deseada




Figura 10.- Ejemplo en obtencion de la mejor topologia para el caso de 7 esferas maximizada

Como se puede observar se obtienen 3 distintas topologias que son normal, deseada y maximizada, que para este caso se tomaran solo las normales y maximizadas ya que las normales y deseadas son las mismas topologias.

3.4 Confirmación

Para esta ultima etapa se hicieron varios pasos para confirmar lo que se realizó anteriormente y asi poder determinar si es posible la reduccion de las esferas.

A partir de los resultados del analisis estadistico JMP se tomaron las mejores topologias obtenidas que son 4 normales y 4 maximizadas (una por cada caso de esfera) estas se volvieron a entrenar 4 veces por cada caso, despues por medio de la obtención de las graficas de χ^2 y R se compararon las topologias y se eligieron las mejores para cada numero de esferas, que para este caso resultaron mejores las normales, que se muestran en la siguiente tabla:

Tabla 1.- Obtención de las mejores Topologías

Gpo	Núm. de esferas	Tamaño de cada esfera (pulgadas)	Neuronas en capa oculta 1	Neuronas en capa oculta 2	Tasa de aprendizaje	Momento	Error
1	7	0, 2, 3,5,8,10 y 12	10	0	0.001	0.001	2.5E-4
2	2	8 y 5	10	0	0.001	0.001	4.5E-4
3	1	8	10	0	0.001	0.001	5.0E-4
4	1	5	10	0	0.001	0.001	5.2E-4

Después de obtener las mejores topologías (normales) mostradas anteriormente se compararon de igual manera con χ^2 y R, así como la comparación del mejor y peor espectro obtenido.




Figura 11.- Comparación de R entre las mejores Topologías

Como se observa en la figura anterior las Topologías con mejor correlación son las de 7 y 2 esferas, las de una esfera para cualquier tamaño también pueden funcionar pero teniendo en

cuenta que tienen más errores, esto se puede observar en la gráfica pues estas tienen unos picos muy abajo y al contrario de estas las de 7 y 2 esferas se mantienen más cerca de 1 que es lo que se espera para cada caso.




Figura 12.- Comparación de χ^2 entre las mejores Topologías

En el caso de la χ^2 los valores deben estar cercanos a cero, con un rango de 0 a 43.1880, como se puede observar en la figura anterior los valores de las esferas 2 y 7 son mejores pues se mantienen más cerca a cero y dentro del rango, caso contrario al de una esfera que tienen menos estabilidad, pues contienen un mayor número de picos y en algunos casos fuera del rango.

Para el caso de los espectros se tomó solo uno de los ejemplos que fue el de 7 esferas para el mejor y peor caso que a continuación se muestran:




Figura 13.- Mejor espectro obtenido para el caso de 7 esferas comparado con el mismo espectro de las demás esferas (casos)




Figura 14.- Peor espectro obtenido para el caso de 7 esferas comparado con el mismo espectro de las demás esferas (casos)

4.- DISCUSIÓN

La metodología de diseño robusto fue de gran importancia para la realización de este proyecto, ya que al aplicar cada una de las etapas que lo conforma, es mucho más fácil su comprensión en la parte de los resultados obtenidos, al entrenar las redes para cada uno de los casos de esferas se obtuvieron los arreglos ortogonales y de allí la mejor Topología mediante el análisis en JMP, después de esto se volvió a entrenar y comparar por medio de R y χ^2 para ver los comportamientos de cada uno de estos, también se hizo comparación con los mejores y peores espectros de cada caso con los demás y de allí determinar si se puede alcanzar el objetivo de disminuir el número de esferas.

5.- CONCLUSIONES

La aplicación de la tecnología de redes neuronales artificiales considerada como una alternativa útil en la espectrometría de neutrones, con ayuda de la estrategia de MDRRNA, ofrecen una forma conveniente de considerar simultáneamente variables de diseño y de ruido, e incorporar el concepto de robustez en el proceso de diseño de las redes, así como la aplicación de varios experimentos usando el sistemas espectrométrico de esferas Bonner, que en el caso de este proyecto se usaron 4 casos que son: para 7 esferas, 2 esferas, 1 esfera de 8 pulgadas y 1 de 5 pulgadas.

Dentro de los resultados obtenidos hasta ahora, se puede mencionar que hay respuestas alentadoras para disminuir el número de esferas, pero aún se encuentra en proceso el análisis de la información, como se vio en los resultados en las gráficas de R y χ^2 cumplen con los parámetros requeridos de una R cerca de 1 y una χ^2 cerca de 0, en la parte de los espectros se observa que son muy parecidos los obtenidos a los esperados como es el caso de las 7 y 2 esferas, pero en el caso de las de una esfera su error es un poco más grande.

Agradecimientos

Este trabajo fue parcialmente financiado por el Fondo de Investigación para la Educación bajo contrato 241771

Este trabajo fue parcialmente financiado por fondos Mixtos SEP-CONACYT bajo contrato ZAC-C03-2015-26357-4.

Este trabajo fue parcialmente financiado por PROSOFT bajo contrato 201513723.

El primero, tercero y cuarto autor agradecen la beca de Licenciatura con número de becario 23241, 23238 y 23240 respectivamente, por Fondo Sectorial de Investigación para la Educación bajo contrato 241771.

El segundo y quinto autor agradecen a la beca de Doctorado con número de becario 23386 y 23385 respectivamente recibido por Fondo Sectorial de Investigación para la Educación bajo contrato 241771.

REFERENCIAS

Bakali M. *Espectrometría neutrónica en las centrales nucleares mediante un sistema de esferas Bonner*. PhD thesis, Universidad Autónoma de Barcelona. (2001)

Cember H. *INTRODUCTION TO HEALTH PHYSICS*. McGraw-Hill, 3rd Edition (1996).

Del Hoyo-Becerra A. *Prueba, validación y documentación del código para espectrometría y dosimetría de neutrones NSDann.*, Tesis de Licenciatura de la Universidad Autónoma de Zacatecas. (2013).

- Martínez-Blanco MR. *Espectrometría de neutrones y cálculo simultáneo de dosis equivalentes empleando la metodología de diseño robusto de redes neuronales*. Tesis de Licenciatura de la Universidad Autónoma de Zacatecas. (2016).
- Martínez-Blanco MR, Ortiz-Rodríguez JM & Vega-Carrillo HR. (2006) *Neutron spectrometry and dosimetry by means of bonner spheres system and artificial neural networks applying robust design of artificial neural networks*. Memorias del IX International Symposium/XIX National Congress on Solid State Dosimetry: 203-208.
- Ortiz-Rodríguez JM, Martínez-Blanco MR, Arteaga-Arteaga T, Vega-Carrillo HR; Hernández-Dávila VM & Manzanares-Acuña E. (2005). *Reconstrucción de espectros de neutrones usando redes neuronales a partir del sistema espectrométrico de esferas de Bonner*. Memorias del VIII International Symposium/XVIII National Congress on Solid State Dosimetry. Pp. 20.
- Ortiz-Rodríguez J.M. *Diseño robusto de redes neuronales artificiales aplicadas a la espectrometría de neutrones*. Tesis de Maestría de la Universidad Autónoma de Zacatecas. (2005).
- Reyes-Alfaro A; Ortiz-Rodríguez, JM; Reyes-Haro, A; Castañeda-Miranda R; Solis-Sánchez LO & Vega-Carrillo HR. (2014). *Optimización de redes neuronales artificiales para la reconstrucción del espectro de neutrones y sus dosis equivalentes*. Proceedings of the ISSSD 2014: 475-494.
- Reyes-Haro, A., Ortiz-Rodríguez J.M. & Vega-Carrillo. H.R. *Código Iterativo para la Reconstrucción del Espectro de Neutrones usando las Esferas Bonner*, Proceedings of the ISSSD 2012: 44-49.
- Unal, R. & Dean EB. (1991). *Taguchi approach to design optimization for quality and cost: An overview*. 1991 Annual Conference of the International Society of Parametric Analysis. Pp. 10.

Entrenamiento de Redes Neuronales de Propagación Inversa Aplicadas a la Dosimetría de Neutrones

Cruz Felipe Hernández-Pérez¹⁻³, Ma. del Rosario Martínez-Blanco¹⁻³, Ana Alicia León-Pérez^{1-3*}, J. Guadalupe Espinoza-García¹⁻³, Víctor Hugo Castañeda-Miranda¹⁻³, Luis Octavio Solís-Sánchez¹⁻³, Rodrigo Castañeda-Miranda¹⁻³, Hector Rene Vega-Carrillo⁴, Roberto Méndez Villafañe⁵, Eduardo Gallego⁶, Marco Aurelio de Sousa Lacerda⁷ y José Manuel Ortiz-Rodríguez¹⁻³

Universidad Autónoma de Zacatecas, Av. Ramón López Velarde 801, Col. Centro 98000, Zacatecas, México.

¹ Centro de Investigación e Innovación Tecnológica Industrial (CIITI)

² Laboratorio de Innovación y Desarrollo Tecnológico en Inteligencia Artificial (LIDTIA)

³ Unidad Académica de Ingeniería Eléctrica

⁴ Unidad Académica de Estudios Nucleares (UAEN)

⁵ Laboratorio de Patrones Neutrónicos del Departamento de Metrología de Radiaciones Ionizantes del Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas (CIEMAT), Avda. Complutense, 22, 28040, Madrid, España

⁶ Departamento de Ingeniería Nuclear de la Universidad Politécnica de Madrid (DIN-UPM), ETSI Industriales, C. José Gutiérrez Abascal, 2, 28006, Madrid España

⁷ Centro de Investigación de Tecnología Nuclear de la Comisión Nacional de Energía Nuclear (CDTN-CNEN), Av. Presidente Antonio Carlos, 6627, Pampulha, CEP: 31270-901, Belo Horizonte, MG, Brazil

RESUMEN

La dosimetría de neutrones es de gran importancia en la protección radiológica ya que tiene como objetivo proporcionar cantidades dosimétricas para valorar la magnitud de los efectos detrimentales en la salud debido a la exposición de radiación de neutrones. Para cuantificar el detrimento a la salud es necesario evaluar la dosis recibida por el personal ocupacionalmente expuesto utilizando diferentes sistemas de detección llamados dosímetros, los cuales poseen respuestas muy dependientes de la distribución de energía de los neutrones. La detección de neutrones es un problema mucho más complejo que la detección de partículas cargadas, ya que no transporta una carga eléctrica, no causan ionización directa, y posee un poder de penetración mayor dándole la posibilidad de interactuar con la materia de manera distinta. Debido a esto se han

desarrollado diversos sistemas de detección de neutrones entre los que destaca el sistema espectrométrico de esferas Bonner debido a las ventajas que posee, tales como un amplio rango de energía, alta sensibilidad y fácil operación. Sin embargo, una vez obtenidas las tasas de conteo, el problema radica en la deconvolución del espectro de neutrones, necesario para el cálculo de las dosis, para lo que se emplean diferentes métodos matemáticos tales como Monte Carlo, máxima entropía, métodos iterativos, entre otros, mismos que presentan diversas dificultades que han motivado el desarrollo de nuevas tecnologías. En la actualidad se están empleando métodos basados en tecnologías de inteligencia artificial para realizar la dosimetría de neutrones, utilizando principalmente la teoría de redes neuronales artificiales. En estos nuevos métodos se puede eliminar la necesidad de reconstrucción del espectro para el cálculo de las dosis. En este trabajo se entrenó una red neuronal artificial de propagación inversa para el cálculo de 15 dosis equivalentes a partir de las tasas de conteo del sistema espectrométrico de esferas Bonner utilizando un conjunto de 7 esferas, uno de 2 esferas y 2 de una sola esfera de diferentes tamaños, probando diferentes valores de error hasta encontrar el más apropiado. La topología de red óptima se obtuvo mediante la metodología de diseño robusto de redes neuronales artificiales donde se seleccionaron los parámetros de la red que produjo los mejores resultados.

Palabras clave: Dosimetría de neutrones; protección radiológica; esferas Bonner; diseño robusto.

1.- INTRODUCCIÓN

1.2.- Dosimetría de neutrones

Debido a la complejidad de las interacciones de los neutrones con el entorno el poder determinar con precisión su energía resulta en una tarea difícil. Al ser partículas que no poseen carga son difíciles de detectar además de tener un poder de penetración mayor que las partículas cargadas y la radiación electromagnética lo que genera un problema para la protección radiológica, que tiene como objetivo el proporcionar un método para valorar la magnitud de los efectos detrimentales en la salud debido a la exposición de radiación de neutrones. Dentro de la protección radiológica la espectrometría y dosimetría de neutrones resultan ser de gran importancia, sin embargo, estas son de las tareas más complejas dentro de esta área. [Thomas 2004; Reyes-Haro *et al.*, 2012, Reyes-Haro *et al.*, 2014]

1.3.- Sistema espectrométrico de esferas Bonner

En espectrometría y dosimetría de neutrones, el sistema espectrométrico de multiesferas, también llamado sistema espectrométrico de esferas Bonner (SEEB), ha sido uno de los métodos más utilizado para la detección de neutrones debido a las ventajas que proporciona, tales como, poseer un extenso rango de energía que va desde los neutrones térmicos hasta los neutrones de alta energía (GeV), funciones de respuesta simple, casi isotrópica, alta sensibilidad y fácil operación. Sin embargo este sistema también cuenta con algunas desventajas como tener una resolución muy baja y requerir largos espacios y periodos de tiempo para la irradiación. [Wang *et al.*, 2014; Tripathy *et al.*, 2009]

Este sistema está conformado por un detector y diversas esferas de polietileno de diversos tamaños expresados en pulgadas. El detector se coloca en el centro de las esferas las cuales actúan como moderadores reduciendo la incidencia de neutrones de alta energía a menores energías, además, el simple detector desnudo es sensible a la irradiación de neutrones térmicos. Las mediciones de un campo de neutrones particular se realizan tomando esferas

de diferentes tamaños. [Thomas & Alevra 2002; Freeman, Edwards & Bolon, 1999; Bramblett, Ewing & Bonner, 1960]

Casi todos los detectores o espectrómetros se enfrentan al problema de la reconstrucción del espectro, requerido para el cálculo de las cantidades dosimétricas, cuando se utilizan para la caracterización de un campo de neutrones. El SEEB no es la excepción, el espectro de neutrones no es dado directamente como resultado de las mediciones realizadas con el sistema, siendo necesario emplear algún método matemático tal como Monte Carlo, Máxima Entropía, Métodos Iterativos, entre otros [Suman & Sarkar, 2014, Freeman, Edwards & Bolon, 1999]. Sin embargo estos métodos matemáticos también presentan diversas dificultades como la necesidad de un espectro inicial similar al que se desea obtener o el conocer bien el uso de la herramienta diseñada en un entorno no amigable para usuarios no expertos. Esto ha motivado el desarrollo de nuevas tecnologías basadas en inteligencia artificial tales como algoritmos genéticos (AG) y redes neuronales artificiales (RNA). [Vega-Carrillo, Ortiz-Rodriguez & Martinez-Blanco, 2012; Mohammadi, Hakimabad & Motavalli, 2015]

1.4.- Redes neuronales artificiales

Las redes neuronales artificiales se componen de elementos simples que funcionan en paralelo. Estos elementos están inspirados en los sistemas nerviosos biológicos. Como en la naturaleza, la función de red se determina en gran parte por las conexiones entre elementos. Podemos entrenar una red neural para realizar una función particular, mediante el ajuste de los valores de las conexiones (pesos sinápticos) entre los elementos. Una red neuronal tiene tres tipos de capas; de entrada, oculta y de salida. Cada capa tiene varias neuronas que se conectan con otras neuronas a través de pesos y sesgos. Las capas también están conectados entre sí con las funciones de activación. Durante el entrenamiento de la RNA se emplea un conjunto de datos con información de entrada y salida, y los pesos de las neuronas se ajustan hasta que se consigue el patrón entre los datos de entrada y salida. El algoritmo de

aprendizaje de una RNA es el proceso de adaptación que define y modificar los pesos y sesgos. El entrenamiento tiene el propósito de seleccionar los pesos que se adaptan mejor a la red en relación con los datos de entrenamiento. [Mohammadi, Hakimabad & Motavalli, 2015]

El uso de RNA ha resultado ser una gran opción dentro de la dosimetría de neutrones, sin embargo, de los obstáculos principales al emplear RNA de propagación resulta en la búsqueda óptima de los pesos sinápticos de la red, que es altamente dependiente de los pesos iniciales y si éstos están localizados cerca de un mínimo local, el algoritmo podría quedar atrapado, lo que podría ocasionar un pobre desempeño de la red que esté siendo diseñada (Jain, Mao & Mohiuddin, 1996). Otras limitaciones de las RNA son: la determinación de la arquitectura de red, la selección del algoritmo de entrenamiento, el uso de datos de entrenamiento confiables y la relación entre los procesos, todas estas limitaciones han motivado a los investigadores a generar ideas para fusionar las RNA con otros métodos en la búsqueda de un mejor desempeño [Ortiz-Rodríguez, Martínez-Blanco & Vega-Carrillo, 2008].

El objetivo de este trabajo es determinar si es posible reducir el número de esferas utilizadas por el SEEB para la medición de fluencia de neutrones por medio de la optimización de la arquitectura de una red neuronal multicapa de propagación inversa, mediante la Metodología de Diseño Robusto de Redes Neuronales Artificiales (MDRRNA) [Ortiz-Rodríguez 2005; Ortiz-Rodríguez, Martínez-Blanco & Vega-Carrillo, 2006], entrenada para el cálculo de 15 cantidades dosimétricas haciendo uso de las tasas de conteo obtenidas con el SEEB con 4 grupos diferentes de esferas,

2.- MATERIALES Y METODOS

Se utilizaron un compendio de 251 conjuntos de datos compilados por el Organismo internacional de Energía Atómica, que contiene 15 cantidades dosimétricas cada grupo de datos, se utilizaron las tasas de conteo obtenidos de 4 diferentes grupos de esferas del SEEB para el entrenamiento de una red neuronal de propagación hacia adelante con algoritmo de propagación inversa para el cálculo de 15 cantidades dosimétricas, con la finalidad de conocer si es posible reducir el número de esferas empleadas por el SEEB y aun obtener una respuesta satisfactoria. El número de esferas usadas así como sus dimensiones se muestran en la tabla 1.

Tabla 1.- Grupos de esferas utilizados.

Grupo	Numero de esferas	Tamaño de esfera [pulgadas]
1	7	0, 2,3, 5, 8, 10, 12
2	2	8, 5
3	1	8
4	1	5

Se hace uso de la metodología de diseño Robusto de Redes Neuronales Artificiales para la selección de los parámetros óptimos de la arquitectura de una red neuronal artificial aplicada en el ámbito de la dosimetría de neutrones. El método de diseño robusto hace uso de la metodología Taguchi que utiliza una herramienta matemática llamada arreglo ortogonal para estudiar una gran cantidad de variables de decisión con un número pequeño de experimentos. El uso de esto arreglos ortogonales reduce significativamente el número de configuraciones experimentales a ser estudiadas a un punto practico donde aún se es capaz de alcanzar una solución óptima. [Jiju & Frenie Jiju 2001; Unal & Dean 1991]

La metodología de diseño robusto es un método experimental, el cual está compuesto de 4 etapas principales, cada una de las cuales contiene un determinado número de pasos. La figura 1 muestras las etapas la MDRRNA.

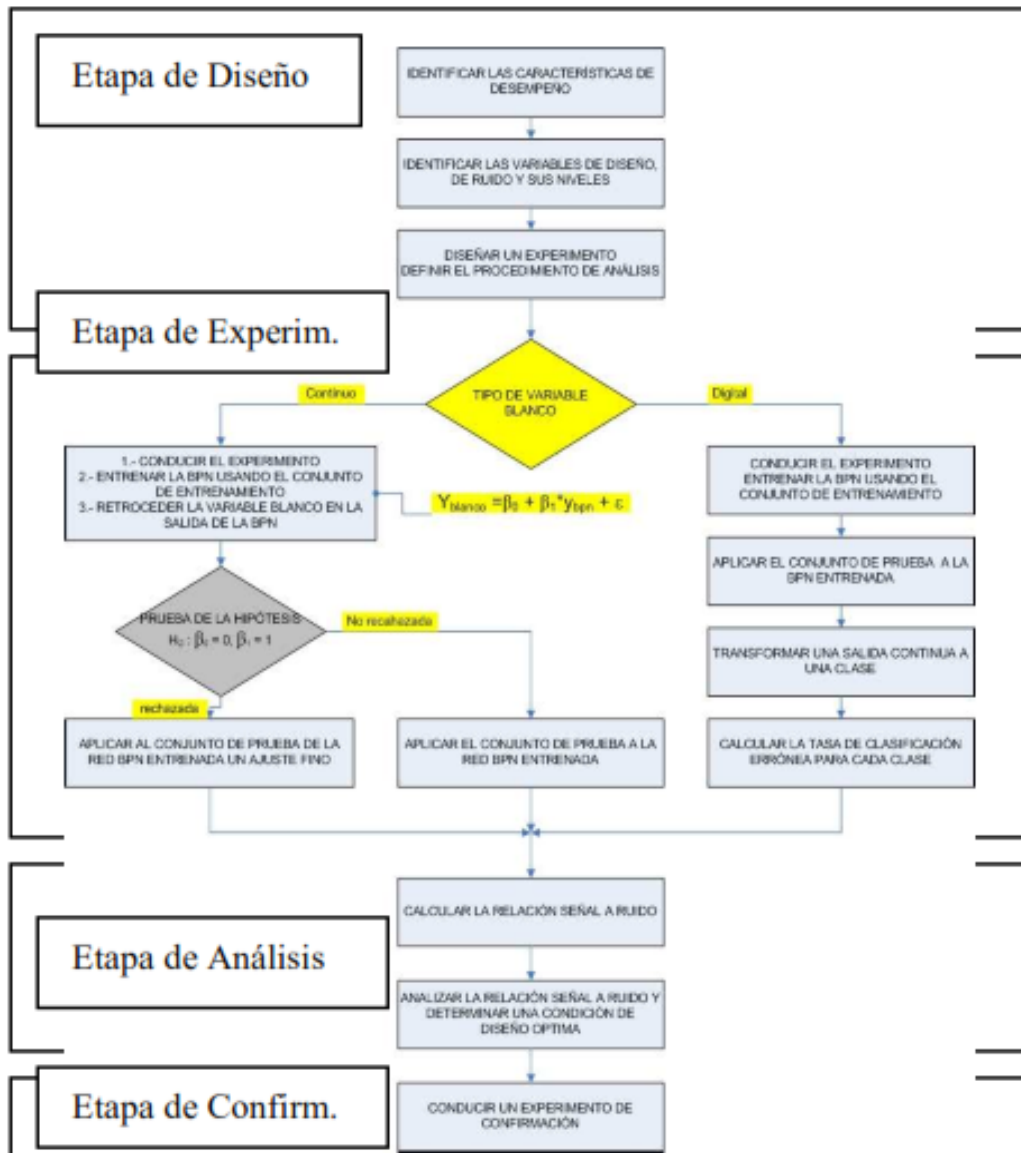


Figura 1.- Etapas de la Metodología de diseño robusto de redes neuronales artificiales.

2.1.- Etapa de planeación

En la etapa de planeación es necesario identificar la función objetivo y la búsqueda de las variables de diseño y de ruido que se encuentran dentro de la región de búsqueda. Las variables de diseño son parámetros que podemos controlar mientras que las variables de

ruido son parámetros que no pueden ser controlados y la función objetivo es la salida del error cuadrático medio (MSE) también conocido como el desempeño de la RNA.

En este trabajo se eligieron 4 variables de diseño, tal como se muestra en la tabla 2 donde se consideraron tres niveles para cada variable de diseño, para el diseño de la topología de la red. Donde A es el número de neuronas de la primera capa oculta, B es el número de neuronas de la segunda capa oculta, C es la tasa de aprendizaje y D es el momento, siendo estos los parámetros controlables con mayor influencia sobre la red.

Tabla 2.- Variables de diseño y sus niveles.

Variabes de diseño	Nivel 1	Nivel 2	Nivel 3
A			
B			
C			
D			

En la tabla 3 se muestran las variables de ruido seleccionadas, se eligieron 3 variables con 2 niveles cada una. Donde U es el conjunto inicial de pesos sinápticos, V es la relación del tamaño de datos usados para entrenamiento y prueba W es la selección aleatoria de los conjuntos de datos de entrenamiento y prueba, U representa la relación en porcentaje de datos utilizados por W.

Tabla 3.- Variables de ruido y sus niveles.

Variabes de ruido	Nivel 1	Nivel 2
U	Conjunto 1	Conjunto 2
V	E:P	E:P
W	Entrenamiento 1-Prueba 1	Entrenamiento 2-Prueba 2

2.2.- Etapa de experimentación

En esta etapa de acuerdo con la MDRRNA, para el diseño de la topología de la red neuronal se seleccionaron las variables de diseño y de ruido conforme con las tablas 1 y 2, como sugiere el

método Taguchi se usó un arreglo ortogonal cruzado $L_r(G^c)$, donde r es el número de renglones, c es el número de columnas y G el número de niveles en cada columna. Se utilizó un arreglo ortogonal con configuración $L_9(3^4)$ y $L_4(2^3)$, como puede observarse en la tabla 3.

Tabla 4.- Parámetros de optimización de la RNA

No. Exp.	A	B	C	D	G1	G2	G3	G4	Media de Y	Relación S/R
					U=1	U=1	U=2	U=2		
					V=1	V=2	V=1	V=2		
					W=2	W=1	W=1	W=2		
1	1	1	1	1						
2	1	2	2	2						
3	1	3	3	3						
4	2	1	2	3						
6	2	2	3	1						
6	2	3	1	2						
7	3	1	3	2						
8	3	2	1	3						
9	3	3	2	1						

Se realizaron 36 entrenamientos para las diferentes topologías mostradas en el arreglo ortogonal, utilizando una herramienta diseñada en el entorno de programación de MATLAB, para la obtención de los desempeños de las redes, utilizados para el llenado del arreglo ortogonal.

Se utilizaron los datos obtenidos de 4 diferentes grupos de esferas del SEEB y se usó un arreglo ortogonal para cada uno lo que significa que se realizaron 36 entrenamientos diferentes para cada grupo de esferas.

2.3.- Etapa de análisis

Al finalizar con el llenado del arreglo ortogonal y en base a los resultados obtenidos, se calculó la relación señal-ruido por medio de la técnica del análisis de la varianza, con el fin

de determinar los efectos significativos y los niveles óptimos de las variables de diseño de la red y así obtener las mejores posibles topologías que tengan un mejor desempeño. El análisis de la varianza se realizó con la ayuda del programa estadístico JMP. Con los valores obtenidos del análisis de la relación señal-ruido y usando el programa estadístico JMP se calcularon los mejores parámetros de diseño para la RNA, obteniéndose las posibles mejores topologías de red, las cuales se entrenaron nuevamente utilizando la herramienta diseñada en MATLAB con el fin de elegir aquella con un mejor desempeño y capacidad de generalización. Se entrenaron cada topología obtenida un total de 4 veces cada una, utilizando el mismo porcentaje y los mismos datos para la etapa de entrenamiento y prueba, reduciendo así las variables no controlables.

2.4.- Confirmación

Con los resultados obtenidos de los entrenamientos realizados en la etapa de análisis se compararon el comportamiento de las redes de cada grupo de esferas con el fin de elegir la mejor de cada grupo, que contenga los mejores pesos sinápticos, aplicando la prueba de correlación (R) y chi cuadrada (χ^2). Obtenida la mejor red de cada grupo de esferas se compararon ahora entre ellas realizando nuevamente las pruebas de R y χ^2 para conocer el funcionamiento de cada red en comparación con la demás. Finalmente se compararon el mejor y el segundo peor caso de cálculo de dosis de cada red, obtenidos de la etapa de prueba de la red, así como 2 casos aleatorios.

3.- RESULTADOS

Aplicando la MDRRNA y siguiendo cada una de sus etapas se obtuvieron los siguientes resultados para cada grupo de esferas utilizado en este trabajo.

3.1.- Etapa de planeación

De acuerdo a la MDRRNA, para diseñar la estructura de la red neuronal se seleccionaron las variables de diseño y de ruido como se muestra en la tabla 5 y 6.

Tabla 5.- Variables de diseño y sus niveles.

VARIABLES DE DISEÑO	Nivel 1	Nivel 2	Nivel 3
A	5	10	15
B	0	10	15
C	0.001	0.1	0.3
D	0.001	0.05	0.1

Tabla 6.- Variables de ruido y sus niveles.

VARIABLES DE RUIDO	Nivel 1	Nivel 2
U	Conjunto 1	Conjunto 2
V	6:4	8:2
W	Entren1-Prueba1	Entren2-Prueba2

3.2.- Etapa de experimentación y análisis

Inicialmente en la etapa de planeación se estableció un error de 1E-04 sin embargo este no resultó ser el mejor error para la red, por lo que se entrenó a prueba y error, utilizando los parámetros de diseño de la red de la etapa de planeación. Se buscó el error mínimo para el cual funciona la red para cada grupo de esferas, quedando como se muestra en la tabla 7.

Tabla 7.- Grupos de esferas utilizados.

Grupo	Numero de esferas	Tamaño de esfera [pulgadas]	MSE
1	7	0, 2, 3, 5, 8, 10, 12	5.5E10-06
2	2	8, 5	4E10-05
3	1	8	1.8E10-05
4	1	5	6.3E10-05

Definido el error para cada grupo de esferas entrena la red y se llena el arreglo ortogonal con los desempeños obtenidos de cada entrenamiento y se realizó el análisis de la relación señal-ruido con el análisis de la varianza con ayuda del programa estadístico JMP, como se muestra en las tablas 8-11.

Tabla 8.- Parámetros de optimización de la RNA para del grupo de 7 esferas.

No. Exp.	G1	G2	G3	G4	Media de Y	Relación S/R
	U=1	U=1	U=2	U=2		
	V=1	V=2	V=1	V=2		
	W=2	W=1	W=1	W=2		
1	8.29E-06	5.57E-06	4.23E-06	5.51E-06	5.90E-06	-11.033566
2	6.87E-06	6.90E-06	1.05E-05	4.90E-06	7.28E-06	-10.249393
3	6.10E-06	6.68E-06	1.73E-05	5.46E-06	8.89E-06	-5.0923811
4	6.22E-06	4.03E-06	5.85E-06	4.34E-06	5.11E-06	-13.575618
6	6.26E-06	5.88E-06	1.00E-05	8.22E-06	7.60E-06	-12.137748
6	5.89E-06	3.89E-06	3.51E-06	6.20E-06	4.87E-06	-11.260633
7	1.23E-05	6.74E-06	8.73E-06	5.99E-06	8.45E-06	-9.8148471
8	4.30E-06	9.33E-06	7.81E-06	4.60E-06	6.51E-06	-8.8890723
9	9.44E-06	6.86E-06	5.12E-06	7.11E-06	7.13E-06	-12.263959

Tabla 9.- Parámetros de optimización de la RNA para del grupo de 2 esferas.

	G1	G2	G3	G4		
No. Exp.	U=1	U=1	U=2	U=2	Media de Y	Relación S/R
	V=1	V=2	V=1	V=2		
	W=2	W=1	W=1	W=2		
1	4.13E-05	3.22E-05	4.41E-05	5.566E-05	4.33E-05	-13.195277
2	4.78E-05	5.14E-05	1.21E-04	7.30E-05	7.33E-05	-7.3951548
3	5.43E-05	9.12E-05	5.32E-05	5.17E-05	6.26E-05	-10.602328
4	2.59E-05	3.72E-05	4.80E-05	4.20E-05	3.83E-05	-12.415225
6	5.90E-05	2.47E-05	5.15E-05	3.87E-05	4.35E-05	-9.5866609
6	5.96E-05	5.04E-05	3.46E-05	4.31E-05	4.69E-05	-13.054584
7	5.15E-05	4.68E-05	4.10E-05	3.95E-05	4.47E-05	-18.178096
8	4.14E-05	3.34E-05	3.33E-05	6.06E-05	4.22E-05	-10.598447
9	7.67E-05	2.42E-05	3.78E-05	3.97E-05	4.46E-05	-6.7097919

Tabla 10.- Parámetros de optimización de la RNA para del grupo de 1 esfera de 8 pulgadas.

	G1	G2	G3	G4		
No. Exp.	U=1	U=1	U=2	U=2	Media de Y	Relación S/R
	V=1	V=2	V=1	V=2		
	W=2	W=1	W=1	W=2		
1	1.89E-05	1.09E-05	2.13E-05	2.20E-05	1.83E-05	-11.312998
2	2.97E-05	2.79E-05	1.98E-05	2.22E-05	2.49E-05	-14.678531
3	2.22E-05	1.44E-05	1.87E-05	2.60E-05	2.03E-05	-12.440811
4	7.73E-05	2.39E-05	2.34E-05	1.78E-05	3.56E-05	-3.7535232
6	2.85E-05	1.63E-05	1.70E-05	1.63E-05	1.95E-05	-10.555293
6	1.94E-05	1.26E-05	3.36E-05	1.26E-05	1.95E-05	-6.6926055
7	2.26E-05	2.19E-05	4.92E-04	2.19E-05	1.39E-04	-0.4259623
8	1.59E-05	2.58E-05	2.96E-05	2.58E-05	2.43E-05	-12.540991
9	1.62E-05	1.34E-05	2.56E-05	1.34E-05	1.72E-05	-9.7863761

Tabla 11.- Parámetros de optimización de la RNA para del grupo de 1 esfera de 5 pulgadas.

No. Exp.	G1	G2	G3	G4	Media de Y	Relación S/R
	U=1	U=1	U=2	U=2		
	V=1	V=2	V=1	V=2		
	W=2	W=1	W=1	W=2		
1	7.11E-05	6.88E-05	6.97E-05	4.97E-05	6.48E-05	-16.196784
2	6.63E-05	5.05E-05	6.73E-05	7.21E-05	6.41E-05	-16.77257
3	7.33E-05	3.45E-05	6.50E-05	8.14E-05	6.36E-05	-10.169921
4	5.51E-05	7.43E-05	6.10E-05	4.53E-05	5.89E-05	-13.86949
6	6.95E-05	6.11E-05	8.57E-05	6.66E-05	7.07E-05	-16.570144
6	1.01E-04	6.96E-05	6.89E-05	5.57E-05	7.38E-05	-11.930806
7	9.09E-04	5.81E-05	9.72E-05	7.80E-05	2.86E-04	-0.867921
8	6.52E-05	8.12E-05	1.09E-04	5.07E-05	7.67E-05	-10.011406
9	5.64E-04	9.58E-05	8.79E-05	1.31E-04	2.20E-04	-2.2010671

Con la relación señal-ruido obtenida de la etapa de experimentación y el programa JMP se obtuvieron las mejores topologías para cada red, siendo 2 topologías para cada grupo de esferas, estas se entrenaron con una relación entrenamiento-prueba de 80-20 en porcentaje de los datos, posteriormente se compararon los resultados de cada red para elegir aquella con un mejor desempeño y capacidad de generalización, aplicando las pruebas de R y χ^2 . La topología de la mejor red final obtenida para cada grupo de esferas se muestra en la tabla 12.

Tabla 12.- Mejor topología obtenida para cada grupo de esferas.

Grupo	Numero de esferas	Tamaño de esfera [pulgadas]	Arquitectura optimizada				
			Neuronas en capa 1	Neuronas en capa 2	Tasa de aprendizaje	Momento	Error
1	7	0, 2,3, 5, 8, 10, 12	5	15	0.1	0.3	5.5×10^{-06}
2	2	8, 5	10	0	0.001	0.001	4×10^{-05}
3	1	8	15	0	0.05	0.3	1.8×10^{-05}
4	1	5	15	0	0.05	0.3	6.3×10^{-05}

3.3.- Etapa de confirmación

Se hizo una comparación de la mejor red obtenida para cada grupo de esferas para conocer si a pesar de utilizar los datos obtenidos con un diferente número de esferas estas logran resolver la tarea del cálculo de dosis. Se compararon realizando las pruebas de la R y X^2 como se observa en las figuras 2 y 3.




Figura 2.- Prueba de R de los 4 grupos de esferas.

En la figura 2 se puede observar que el conjunto de datos de dosis es capaz de alcanzar el valor óptimo de 1 en la mayoría de los casos, además que los casos en los que la red no es capaz de reconstruir las dosis de manera eficiente son los mismos casos en la red seleccionada para cada grupo de esferas, lo cual nos da a conocer que la red está trabajando de manera similar y es capaz de reconstruir las dosis aun utilizando un número diferente de esferas.




Figura 3.- Prueba de χ^2 de los 4 grupos de esferas.

En la figura 3 se observa que en la mayoría de los casos los valores son aproximados a 0 que es lo que se busca, además de que todas se encuentran dentro del valor crítico que es de 6.57, esto nos dice que no existe una gran diferencia entre las dosis calculadas por la red y las dosis deseadas.

Con el fin de confirmar que se comportan de manera similar se compararon el mejor caso para el cual cada red genero una mejor respuesta así como el segundo peor caso de cada red y 2 casos tomados aleatoriamente de los 50 casos de prueba utilizados. La comparación de las dosis calculadas por cada red que emplea cada grupo de esferas y las dosis que se tienen como objetivo se muestran en las figuras 4 a la 12.




Figura 4.-Comparacion del mejor caso obtenido para 7 esferas (caso 3/50).




Figura 5.-Comparacion del mejor caso obtenido para 2 esferas (caso 31/50).




Figura 6.-Comparacion del mejor caso obtenido para 1 esfera de 8 pulgadas (caso 6/50).




Figura 7.-Comparacion del mejor caso obtenido para 1 esfera de 5 pulgadas (caso 46/50).




Figura 8.-Comparacion del segundo peor caso obtenido para 7 esferas (caso 27/50).




Figura 9.-Comparacion segundo peor caso 2 esferas y 1 esfera de 5 pulgadas (caso 36/50).




Figura 10.-Comparacion del segundo peor caso para 1 esfera de 8 pulgadas (caso 50/50).




Figura 11.-Comparacion del primer caso aleatorio (caso 16/50).




Figura 12.-Comparacion del primer caso aleatorio (caso 25/50).

4.- DISCUSIÓN

La técnica de ensayo y error empleada de forma convencional para obtener la mejor combinación de parámetros de diseño de la RNA ha mostrado ser poco eficiente ya que el diseño obtenido está lejos de ser el más óptimo, produciendo redes de pobre desempeño y baja capacidad de generalización. Además de consumir una gran cantidad de tiempo.

La MDRRNA difiere del método convencional en que adopta una estrategia sistemática experimental, donde se considera la robustez de la red, la cual generalmente no se toma en cuenta en el método convencional. En esta se identifican los parámetros de diseño y de ruido, haciendo uso del diseño robusto de Taguchi para encontrar los mejores parámetros de diseño de las RNA haciendo uso de arreglos ortogonales lo cual significa el reducir el número de experimentos, reduciendo la cantidad de tiempo ocupada en la búsqueda de la obtención de la topología óptima. Esta metodología puede ser empleada, a diferencia de las técnicas convencionales, a cualquier problema sin importar la naturaleza de este, siempre que se utilice una red de propagación hacia adelante entrenada con algoritmo de

propagación inversa, ya que se hace uso de una técnica general para determinar los parámetros óptimos de este tipo de red.

5.- CONCLUSIONES

En este trabajo se aplicó la metodología de diseño robusto de redes neuronales artificiales a la búsqueda de la topología óptima de una red neuronal artificial, aplicada al cálculo de dosis equivalentes de neutrones, esto se realizó para cada uno de los 4 diferentes grupos de esferas descritos, un grupo de 7 esferas de tamaños 0,2,3,5,8,10,y 12 pulgadas, uno de 2 esferas de 5 y 8 pulgadas, un grupo de 1 esfera de 8 pulgadas y 1 grupo de 1 esfera de 5 pulgadas, obteniéndose así 4 diferentes topologías de red que resuelven la misma tarea, esto con el fin de conocer si es posible reducir el número de esferas que pueden ser usadas por el SEEB para la medición de fluencia de neutrones y su posterior cálculo de dosis equivalentes.

El tipo de RNA empleada es de propagación hacia adelante con algoritmo de entrenamiento de propagación inversa, para la cual se entrenó un conjunto de topologías de redes con el objetivo de determinar los parámetros óptimos de cada red que produjera los mejores resultados, es decir, las dosis calculadas con el menor error entre las dosis esperadas y las obtenidas. Los entrenamientos y prueba de las redes se realizaron en una herramienta creada en MATLAB para este fin. Usando el programa estadístico JMP se obtuvieron las mejores topologías las cuales se entrenaron, probaron y compararon sus resultados para la selección de las mejores topologías.

Los resultados obtenidos en el cálculo de las dosis se verificaron aplicando las pruebas de χ^2 y R donde se observa en las figuras 2 y 3 que los resultados de cada red son similares, alcanzando valores cercanos a 1 para la R y valores de 0 para la χ^2 , que son los valores que se buscan alcanzar y son capaces de calcular las dosis de forma muy similar a las esperadas tal como se muestra en las figuras 4-12.

Los resultados obtenidos hasta el momento son alentadores, sin embargo, aún no se puede concluir si es posible reducir el número de esferas ya que los datos aún se encuentran en análisis, siendo necesario la realización de más pruebas estadísticas.

Agradecimientos

Este trabajo fue parcialmente financiado por el Fondo de Investigación para la Educación bajo contrato 241771. Este trabajo fue parcialmente financiado por fondos Mixtos SEP-CONACYT bajo contrato ZAC-C03-2015-26357-4. Este trabajo fue parcialmente financiado por PROSOFT bajo contrato 201513723.

El primero, tercero y cuarto autor agradecen la beca de Licenciatura con número de becario 23238, 23241, y 23240 respectivamente, recibido por Fondo Sectorial de Investigación para la Educación bajo contrato 241771. El segundo y quinto autor agradecen a la beca de Doctorado con número de becario 23386 y 23385 respectivamente, recibido por Fondo Sectorial de Investigación para la Educación bajo contrato 241771.

REFERENCIAS

- Bramblett RL, Ewing RI & Bonner TW. (1960) *A new type of neutron spectrometer*, Nuclear Instruments and Methods **9**: 1-12.
- Freeman DW, Edwards DR & Bolon AE. (1999) *Genetic algorithms – A new technique for solving the neutron spectra unfolding problem*, Nuclear Instruments and Methods in Physics Research A **425**: 549-576.
- Jain AK, Mao J & Mohiuddin KM. (1996). *Artificial neural networks: a tutorial*. IEEE: Computer **29**: 31-44.
- Jiju A & Frenie Jiju A. (2001). *Teaching the Taguchi method to Industrial Engineers*. Work Study **50**: 141-149.
- Mohammadi N, Hakimabad HM, & Motavalli LR. (2015) *Neuronal network of neutron spectrum measured by gold foil-based Bonner sphere*. Journal of Radioanalytical and Nuclear Chemistry **303**: 1687-1693.
- Ortiz-Rodríguez J.M. *Diseño Robusto de Redes Neuronales Artificiales aplicadas a la Espectrometría de Neutrones*. Tesis de Maestría de la Universidad Autónoma de Zacatecas. (2005).

- Ortiz-Rodríguez JM, Martínez-Blanco MR & Vega-Carrillo HR. (2008). *Espectrometría y dosimetría de neutrones por medio de redes neuronales evolutivas*. Memorias del XIX Congreso Anual de la Sociedad Nuclear Mexicana: 130-141.
- Ortiz-Rodríguez J.M., Martínez Blanco M.R., Vega-Carrillo H.R. (2006). *Diseño robusto de Redes Neuronales Artificiales*. Memorias del Encuentro de Investigación en Ingeniería Eléctrica (ENINVIE 2006): 295-300.
- Reyes-Haro A, Ortiz-Rodríguez JM & Vega Carrillo HR. (2012). *Código iterativo para la reconstrucción del espectro de neutrones usando las esferas Bonner*. Proceedings of the ISSSD 2012: 44-49.
- Reyes-Haro A, Ortiz-Rodríguez JM, Reyes-Alfaro A, Castañeda-Miranda R, Solis-Sanchez LO & Vega-Carrillo HR. (2014). *Prueba y validación del código iterativo para la espectrometría y dosimetría de neutrones: NSDUAZ*. Proceedings of the ISSSD 2014: 296-309.
- Suman V & Sarkar PK.(2014). *Neutron spectrum unfolding using genetic algorithm in a Monte Carlo simulation*. Nuclear Instruments and Methods in Physics Research A **737**: 76-86.
- Thomas DJ & Alevra AV. (2002). *Bonner sphere spectrometer-a critical review*. Nuclear Instruments and Methods in Physics Research A **476**: 12-20.
- Thomas DJ. (2004). *Neutron spectrometry for radiation protection*. Radiation Protection Dosimetry **110**: 141-149.
- Tripathy SP, Bakshi AK, Sathian V, Tripathi SM, Vega-Carrillo HR, Nandy M, Sarkar PK & Sharma DN. (2009). *Measurement of ²⁴¹Am-Be spectra (bare and Pb-covered) using TLD pairs in multi-spheres unfolding by different methods*. Nuclear Instruments and Methods in Physics Research A **598**: 556-560.
- Unal R & Dean EB. (1991) *Taguchi Approach to design optimization for quality and cost: An overview*. 1991 Annual Conference of the International Society of Parametric Analysis. Pp.1-10.
- Vega-Carrillo HR, Ortiz-Rodriguez JM & Martinez-Blanco MR. (2012). *NSDUAZ unfolding package for neutron spectrometry and dosimetry with Bonner spheres*, Applied Radiation and Isotopes **71**: 87-91.
- Wang X, Zhang H, Wu Z, Zebg Z, Li JL, Qiu R & Li CY. (2014). *Development of spectra unfolding code for multi-sphere neutron spectrometer using genetic algorithms*, Nuclear Science and Techniques **25**: S010503.

Espectrometría y Dosimetría Neutrónica con Redes Neuronales y Esferas Bonner: Un Estudio para Reducir el Número de Esferas

J. Guadalupe Espinoza-García¹⁻³, Ma. del R. Martínez-Blanco¹⁻³, Ana A. León-Pérez¹⁻³,
Cruz F. Hernández-Pérez¹⁻³, Víctor H. Castañeda-Miranda¹⁻³, Luis O. Solís-Sánchez¹⁻³,
Rodrigo Castañeda-Miranda¹⁻³, Hector Rene Vega-Carrillo⁴, Roberto Méndez⁵,
Eduardo Gallego⁶, Marco A. de Sousa Lacerda⁷, José M Ortiz-Rodríguez¹⁻³

Universidad Autónoma de Zacatecas
Av. Ramón López Velarde 801, Col. Centro 98000, Zacatecas, México.

¹Centro de Investigación e Innovación Tecnológica Industrial (CIITI)

²Laboratorio de Innovación y Desarrollo Tecnológico en Inteligencia Artificial (LIDTIA)

³Unidad Académica de Ingeniería Eléctrica

⁴Unidad Académica de Estudios Nucleares (UAEN)

⁵Laboratorio de Patrones Neutrónicos del Departamento de Metrología de Radiaciones Ionizantes del Centro de Investigaciones Energéticas, Medioambientales y Tecnológicas (CIEMAT)
Avda. Complutense, 22, 28040, Madrid, España

⁶Departamento de Ingeniería Nuclear de la Universidad Politécnica de Madrid
ETSI Industriales, C. José Gutiérrez Abascal, 2, 28006, Madrid España

⁷Centro de Investigación de Tecnología Nuclear de la Comisión Nacional de Energía Nuclear (CDTN-CNEN), Av. Presidente Antonio Carlos, 6627, Pampulha, CEP: 31270-901, Belo Horizonte, MG, Brazil

RESUMEN

Para la espectrometría y dosimetría de neutrones el Sistema Espectrométrico de Esferas Bonner ha sido el sistema más usado, sin embargo, el número, tamaño y peso de las esferas que componen al sistema, la necesidad de utilizar un código de reconstrucción y los largos periodos de tiempo empleados para realizar las mediciones, son algunos de los inconvenientes que este sistema presenta. Para la reconstrucción de los espectros se han usado diferentes técnicas como las redes neuronales artificiales de propagación inversa. El objetivo de este trabajo fue reducir el número de esferas Bonner y usar las rapidezces de conteo en una red

neuronal de propagación inversa, optimizada por medio de la metodología de diseño robusto, para reconstruir los espectros de neutrones. Para el diseño de la red neuronal (RN) se usaron los espectros de neutrones del OIEA y la matriz de respuesta de las esferas Bonner con detector de ${}^6\text{Li}(\text{Eu})$. Se comparó el desempeño de la red usando 7 esferas Bonner que se comparó con el caso donde solo se usan 2 esferas y 1 esfera. Las topologías de red se entrenaron 36 veces para cada caso manteniendo constante el error objetivo ($1\text{E}(-3)$), el algoritmo de entrenamiento fue *trainscg* y la metodología de diseño robusto para determinar las mejores arquitecturas de red. Con éstas, se compararon los mejores y peores resultados. Se encontró que los resultados que se obtienen usando 7 esferas son semejantes a los obtenidos con la esfera de 5 in, sin embargo aún se encuentra en una etapa de análisis de información.

Palabras clave: Espectrometría de neutrones; esferas Bonner, redes neuronales artificiales, optimización.

1.- INTRODUCCIÓN

1.1. Espectrometría y dosimetría de neutrones

El termino espectrometría de radiación puede ser usada para describir la medición de la intensidad de un campo de radiación con respecto a la energía, la frecuencia o momento. La distribución de la intensidad con uno de los parámetros se conoce comúnmente como el "espectro". Una segunda cantidad es la variación de la intensidad de estas radiaciones como una función del ángulo de incidencia sobre un cuerpo situado en el campo de radiación es referido como "dosis" (Reyes-Alfaro et al., 2014). En la espectrometría neutrónica un notable desarrollo se produce con la introducción del método basado en el Sistema Espectrométrico de Esferas de Bonner (SEEB) (Ortiz-Rodríguez, Martínez-Blanco & Vega-Carrillo, 2009), mismo que fue uno de los primeros empleados y que aún sigue siendo de los más utilizados (Ortiz-Rodríguez *et al*, 2013) este consiste en un detector de neutrones térmicos que se coloca en forma alternada en el centro de esferas de polietileno cuyos diámetros son de 2, 3, 5, 8, 10 y 12 pulgadas (Vega-Carrillo, Hernández-Dávila & Manzanares-Acuña, 2003), estas tienen la desventaja de su peso y periodos largos de medición.

1.2. RNA en la espectrometría y dosimetría de neutrones

Se ha propuesto la utilización de redes neuronales artificiales para reconstruir el espectro de neutrones. La importancia de la red backpropagation consiste en su capacidad de autoadaptar los pesos de las neuronas de las capas intermedias para aprender la relación que existe entre un conjunto de patrones de entrada y sus salidas correspondientes. Es importante la capacidad de generalización, facilidad de dar salidas satisfactorias a entradas que el sistema no ha visto nunca en su fase de entrenamiento. (Valencia Reyes, Yáñez Márquez, & Sánchez Fernández, 2006) La red debe encontrar una representación interna que le permita generar las salidas deseadas cuando se le dan entradas de entrenamiento, y que pueda aplicar, además, a entradas no presentadas durante la etapa de aprendizaje para clasificarlas.

1.3 Metodología de Diseño Robusto de Redes Neuronales Artificiales.

En el año 2006 se propone el Diseño Robusto de Redes Neuronales Artificiales (Ortiz-Rodríguez *et al.*, 2006), que implicó el uso de una técnica sistemática y experimental, empleando la metodología de diseño robusto de Taguchi, la cual ofrece beneficios potenciales en el diseño de redes neuronales artificiales. El tamaño y los parámetros de entrenamiento de las RNA tienen un efecto crítico en su desempeño. El método de diseño de experimentos de Taguchi, siendo un método paralelo ofrece beneficios considerables en tiempo y precisión cuando se compara con el método ensayo y error (Reyes-Alfaro, Ortiz-Rodríguez & Vega-carrillo, 2014).

Este trabajo tuvo por objeto la determinación de si es posible reducir el número de esferas Bonner para la espectrometría de neutrones a través de la Metodología de Diseño Robusto de Redes Neuronales Artificiales.

2. MATERIALES Y MÉTODOS

Para este trabajo de investigación se realizó el llenado de 4 veces el arreglo ortogonal correspondiente al arreglo ortogonal de la Metodología de Diseño Robusto de Redes Neuronales Artificiales (MDRRNA), como se muestra en la tabla la cual representa el trabajo realizado para esta etapa en la cual se define la cantidad de neuronas a usar, se entrena 36 veces para el llenado del arreglo ortogonal, posteriormente se hizo la selección de las mejores arquitecturas a través del software estadístico JMP y se entrenó para elegir la mejor inicialización aleatoria de pesos sinápticos. Se aplican pruebas estadísticas como la Chi-cuadrada y la correlación. La MDRRNA (Ortiz-Rodríguez *et al.*, 2013) mostrada en la figura contiene 4 divisiones notorias, La etapa de planeación, etapa de experimentación, etapa de validación y etapa de confirmación, mostrados en la Figura 1.

ETAPA1: DISEÑO

La etapa de diseño que contiene los primeros 3 apartados de la figura 1 consiste en lo siguiente, realizar la obtención de los parámetros de diseño de la red, como lo son el número de capas en la red, de neuronas por capa, el momento la tasa de aprendizaje, se seleccionó para este ejercicio como se muestra en la Tabla 1, valores de 10, 12 y 14 número de neuronas por capa, lo anterior se utiliza para definir un rango hacia adelante y otro hacia atrás de igual se varió la tasa de aprendizaje y el momento, buscando una topología que permita la solución del problema planteado.

Tabla 1.- Variables de diseño y sus niveles

Niveles de las variables de diseño				
Var. Diseño	Nivel 1	Nivel 2	Nivel 3	
A	10	12	14	Neuronas en capa 1
B	0	12	14	Neuronas en capa 2
C	0,001	0,1	0,3	Tasa de aprendizaje
D	0,001	0,05	0,1	Momento

Después se hace una selección de las variables no controlables de la red tales como la inicialización aleatoria de los pesos sinápticos, la relación de los datos de entrada con entrenamiento- prueba y la generación de los conjuntos de información de entrenamiento prueba. Se llama MDDRNA debido a que la metodología es robusta a estas variables de ruido. Se utilizó el 60% y 80% para el conjunto de entrenamiento mostrado en la Tabla 2.

Tabla 2.- Variables de ruido y sus niveles

Niveles de las variables de ruido			
Vars. Ruido	Nivel 1	Nivel 2	
U	Conjunto 1	Conjunto 2	Conjunto inicial aleatorio de pesos
V	6:4	8:2	Relación tamaño de datos Entrenamiento-Prueba
W	Entren1-Prueba1	Entren2-Prueba2	Solución Conjunto Entrenamiento-Prueba

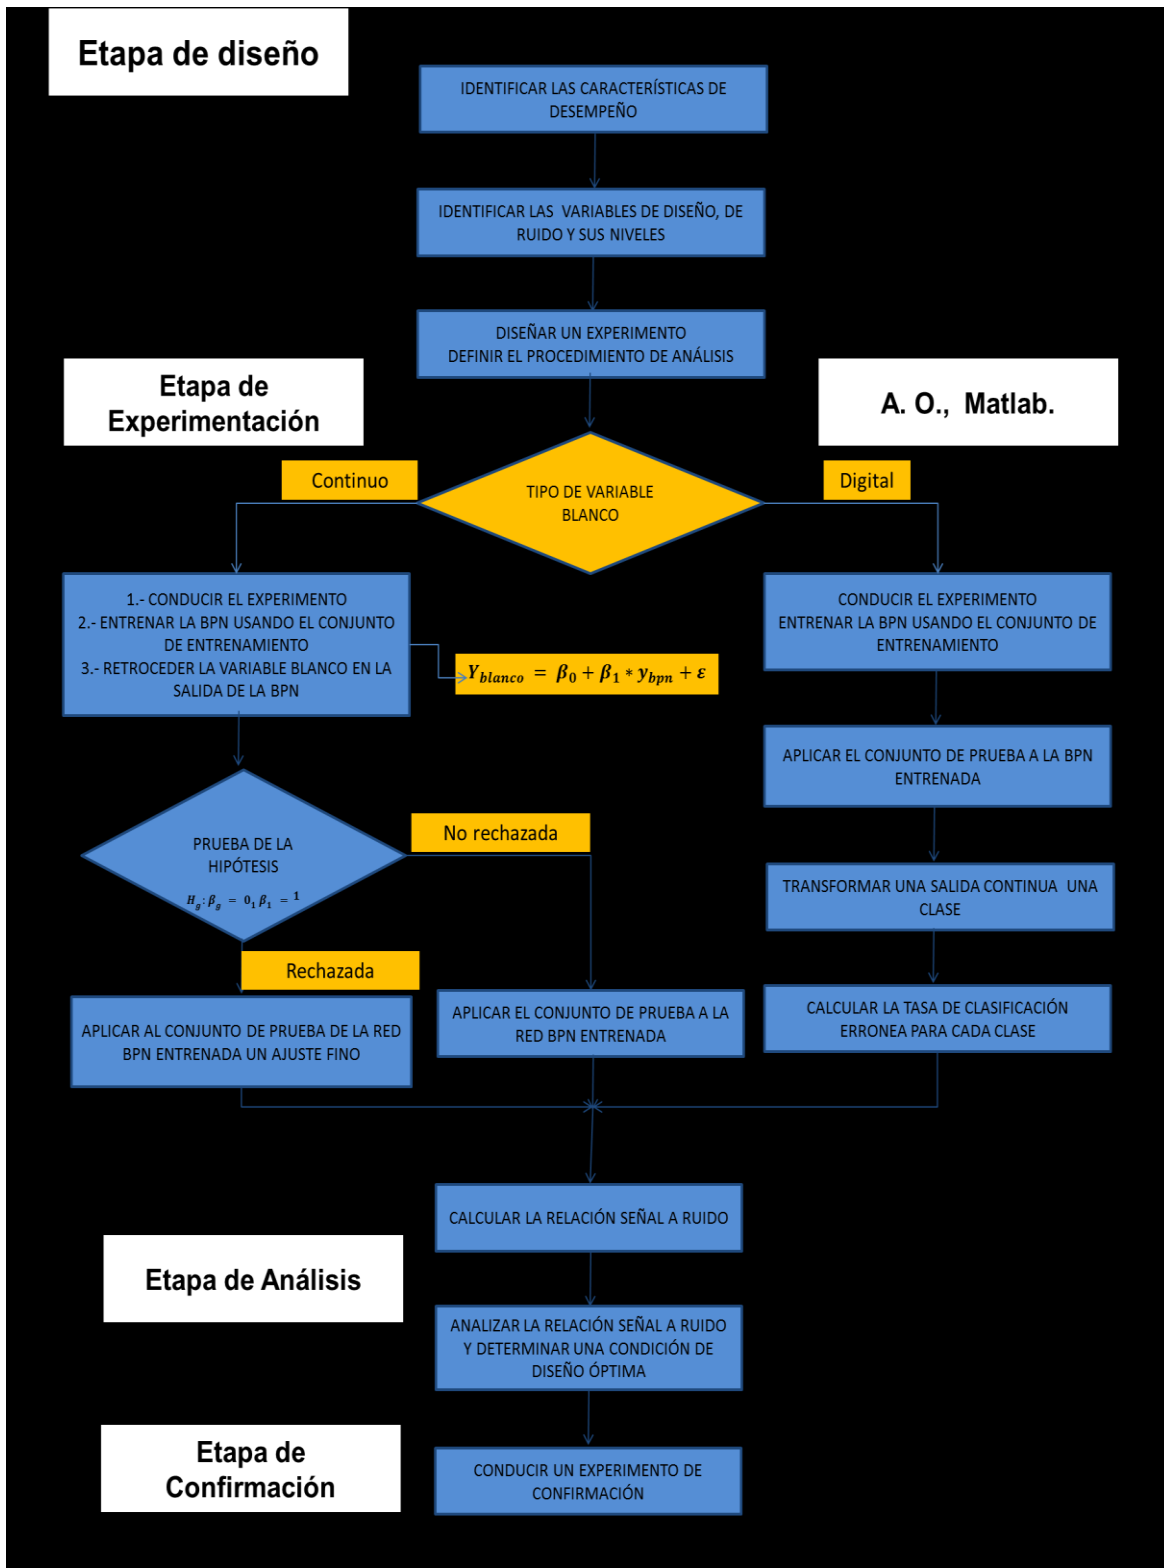


Figura1: Algoritmo para el diseño robusto de redes neuronales artificiales

ETAPA 2: EXPERIMENTACIÓN

Esta comprende el cuadrado del esquema en la figura , y se muestra en la tabla el formato para la parte de la etapa de experimentación en la cual se concentra una cantidad de 36 entrenamientos los cuales usan el conjunto de parámetros determinados en la etapa anterior así como una función de transferencia de entrada aplicada a las capas de entrada e intermedias **logsig**; mientras que en la capa de salida se presenta la información a través de la función **Purelin**, utilizando el algoritmo de entrenamiento de gradiente conjugado **Trainscg**. La implementación de lo anterior se hace con el programa de computo MDRRNA_2_14. Al inicializar el programa se muestra una interfaz con instrucciones sencillas de usar, las cuales son elegidas acorde a la necesidad del usuario. Esta etapa se contiene el principio de la metodología Taguchi en el arreglo ortogonal que se encuentra en la Tabla 3 que se trabaja como sigue: De los parámetros de diseño para el primer caso se toman las variables 1111 además de un error de tolerancia a la red y con ellas se entrena la red y se pone su error cuadrático medio en la casilla 1 de la columna G1y así se llena la tabla completa que se pasa a la etapa de análisis.

Tabla 3.- Experimento Taguchi para la determinación de parámetros de redes neuronales aplicadas a espectrometría y dosimetría de neutrones.

R17										
X	Neuronas en capa 1	Neuronas en capa 2	Tasa de aprendizaje	Momento	G1	G2	G3	G4	Media de Y	Relación S/R
					U=1	U=1	U=2	U=2		
					V=1	V=2	V=1	V=2		
					W=2	W=1	W=1	W=2		
Exp-1111	10	0	0,001	0,001	MSE					
Exp-1222	10	12	0,1	0,05						
Exp-1333	10	14	0,3	0,1						
Exp-2123	12	0	0,1	0,1						
Exp-2231	12	12	0,3	0,001						
Exp-2312	12	14	0,001	0,05						
Exp-3132	14	0	0,3	0,05						
Exp-3213	14	12	0,001	0,1						
Exp-3321	14	14	0,1	0,001						

ETAPA 3: ANÁLISIS

Esta etapa comprende el cálculo de la relación señal a ruido y el análisis de esta y determinar una condición de diseño optima Una vez completados los 36 entrenamientos con convergencia, para cada caso de las diferentes cantidades de mediciones de esferas, se traslada esa información a un software estadístico el cual nos arroja la relación señal a ruido y la mediana, parámetros que usa internamente para producir las posibles mejores topologías de red. El software arroja 3 perfiles diferentes: normal, deseable y deseable maximizado, de los cuales se obtienen 2 topologías diferentes.

ETAPA 4: CONFIRMACIÓN

De perfiles anteriores se reentrenaron cuatro ocasiones para obtener la mejor inicialización de pesos en la red, parámetro que puede afectar de manera considerable el desempeño global de la red. Se aplican pruebas estadísticas de Chi-cuadrada, Correlación, para la elección de la mejor topología. Con lo que se concluye la etapa 4 que consiste en conducir un experimento de confirmación.

3.- RESULTADOS

Se realizó el llenado de el arreglo ortogonal de con el software MDRRNA_2_14. Y se pasó al software estadístico JMP para realizar la obtención de la relación S/N tal como se muestra en la figura 2.

Design	Sc 1	Sc 2	Momento	T.A.	Pattern	Y--	Y+-	Y+-	Y++	Mean Y	SN Ratio Y
1	10	0	0,001	0,001	---	0,00020774	0,00020384	0,00016421	0,00018921	0,00019125	-19,770425
2	10	12	0,05	0,1	-000	0,00041651	0,00016265	0,00012832	0,00020691	0,0002286	-5,8813321
3	10	14	0,1	0,3	+++	0,00014957	0,00053999	0,00016978	0,0001039	0,00024081	-3,3853348
4	12	0	0,1	0,1	0-0+	0,00022407	0,00013931	0,00021381	0,00030552	0,00022068	-10,522386
5	12	12	0,001	0,3	00+-	0,00026799	0,00024211	0,00023783	0,00029622	0,00026104	-19,7493
6	12	14	0,05	0,001	0+-0	0,00017402	0,00016974	0,0001357	0,00028577	0,00018631	-10,772495
7	14	0	0,05	0,3	++0	0,00018948	0,00019632	0,00027641	0,00015794	0,00020504	-12,37535
8	14	12	0,1	0,001	+0+	0,00017097	0,00022199	0,00023896	0,00021328	0,0002113	-17,334263
9	14	14	0,001	0,1	++0-	0,00022904	0,0001518	0,00018456	0,00029268	0,00021452	-11,183316

Figura 2: experimentacion e analisis estadistico con JMP




Figura 3: perfil normal en JMP




Figura 4: perfil deseable en JMP




Figura 5: perfil maximizado en JMP

Se extrajo el perfil normal del JMP mostrado en la Figura 3, el cual contiene la primera de las posibles mejores arquitecturas de red, de igual manera se obtuvo el perfil deseado mostrado en la Figura 4, que coincidió con la arquitectura anterior del perfil normal, también se obtuvo un perfil maximizado mostrado en la Figura 5, en el cual nos arrojó una arquitectura diferente, a la primera Lo anterior se hizo para cada grupo de 7, 2 y 1 esfera correspondientemente. Mientras que en la etapa de confirmación se rentrenaron estas arquitecturas y se eligió la mejor en base a las pruebas estadísticas Correlación y Chi-cuadrada. En la Tabla 4 se muestran los parámetros característicos de cada topología de red para cada uno de los casos entrenados, según su número de datos para entradas. Se ha obtenido la correlación de los desempeños de la red por espectro de energía la cual se muestra en la figura 6, es una comparación de las correlaciones de red para la mejor topología de 7 esferas, una esfera de 5 in, 2 esferas de 5 y 8 in y la de la esfera de 8 in respectivamente. Además al realizar la prueba Chi-cuadrada se arrojaron algunos datos que se salen de los márgenes estadísticos como lo son el correspondiente al espectro 22, 25; se eliminaron de la gráfica para que no afecte la visión de la gran totalidad de los casos, la figura 7 muestra la prueba Chi-cuadrada.

Tabla 4: arquitecturas finales de red

Característica	Caso1	Caso2	Caso 3	Caso 4
Número de entradas	7	2	1	1
Tamaños de esferas (in)	0,2,3,5,8,10, 12	5, 8	5	8
Neuronas en capa 1	10	10	10	10
Neuronas en capa 2	0	0	0	12
Tasa de aprendizaje	0.001	0.001	0.001	0.1
Momento	0.001	0.001	0.001	0.001
Error alcanzado	1.5e-4	4,00E-04	5,00E-04	4.2e-4
Tiempo de entrenamiento (seg)	56.1362	19.8249	0.299449	1.62063
Desempeño de la red	0.000196455	0.000537816	0.000657509	0.000532465
Correlación máxima	0.981295	0.942764	0.8374	0.164833
Chi-cuadrada mínima	0.0273374	0.257979	0.290998	0.938637

Se obtuvo además el mejor espectro que arroja el sistema con diferente cantidad de esferas, donde el encontrado en color negro es el esperado por el compendio de la OIEA el cual se encuentra en la misma forma que los arrojados a la red, descritos a su vez por la leyenda de la Figura 8. De igual manera se obtuvo el peor caso para la obtención del espectro mostrado en la figura 9, el cual muestra discrepancia de los niveles de energía de fluencia de neutrones a lo largo de los espectros. En la Figura 10 se muestra el caso de la mejor respuesta de las 15 dosis ya mencionadas, que se obtienen al entrenar la red, en la figura se muestra que la trayectoria de las 15 dosis de respuesta de la red para cada una de las topologías según su número de entradas. En la figura 11 se aprecia la peor respuesta en dosis de la red de 7 esferas y se observa que la gran mayoría de las dosis diverge de la dosis de 7 esferas.

4.- DISCUSIÓN

Se utilizó el software MDRRNA el cual permitió un análisis de la posible reducción de Esferas Bonner a través de la Metodología de Diseño Robusto de Redes Neuronales Artificiales, después se introdujo la información para su análisis estadístico al software JMP el cual ayudó a realizar la elección de las mejores topologías. A continuación se realizaron pruebas de correlación y Chi-cuadrada para verificar si era posible o no la reducción de esferas para la espectrometría y dosimetría neutrónica, y se presentan resultados alentadores, sin embargo aún se encuentra en una etapa de análisis de resultados.




Figura 6.-Prueba de correlación para las 4 mejores arquitecturas de red




Figura 7.-Prueba de Chi-Cuadrada para las 4 mejores arquitecturas de red




Figura 8.- Mejor espectro obtenido.




Figura 9. Peor espectro obtenido.




Figura 10.-Mejor dosis obtenida




Figura 11.-Peor dosis obtenida

5.- CONCLUSIONES

En base a la prueba de correlación puede apreciar que tienen un comportamiento no muy semejante, la topología obtenida en la red de 7 esferas que ya ha sido usado para validar la herramienta de MDRRNA para su uso la espectrometría y dosimetría neutrónica, con respecto a la topología arrojada por la red con las mediciones realizadas por la esfera de 5 pulgadas como datos de entrada, de igual manera los casos de 8 pulgadas y el de 2 esferas 5 y 8 pulgadas respectivamente, divergen de la respuesta de 7 pulgadas. Cabe mencionar que en la prueba de Chi-cuadrada se apreció que no todos los espectros y dosis convergieron más se eliminaron de la gráfica los picos más destacados para poder observar los datos de los valores bajos que son la gran mayoría, dado que esos valores distorsionan la visualización del gráfico. Los datos mostrados aún son preliminares ya que se encuentra aún en la etapa de análisis de resultados.

Agradecimientos

Este trabajo fue parcialmente financiado por el Fondo de Investigación para la Educación bajo contrato 241771, por fondos Mixtos SEP-CONACYT bajo contrato ZAC-C03-2015-26357-4 y por PROSOFT bajo contrato 201513723. El primero, tercero y cuarto autor agradecen la beca de Licenciatura con número de becario 23240, 23241 y 23238 respectivamente, recibido por Fondo Sectorial de Investigación para la Educación bajo contrato 241771. El segundo y quinto autor agradecen a la beca de Doctorado con número de becario 23386 y 23385 respectivamente, recibido por Fondo Sectorial de Investigación para la Educación bajo contrato 241771.

REFERENCIAS

- Martínez-Blanco MR, Ortiz-Rodríguez JM & Vega-Carrillo HR. (2006). *Espectrometría de neutrones y cálculo de dosis equivalentes, aplicando la metodología de diseño robusto de redes neuronales artificiales*. Memorias del Encuentro de Investigación en Ingeniería Eléctrica (ENINVIE 2006): 301-306.
- Martínez-Blanco MR, Ortiz-Rodríguez JM & Vega-Carrillo HR. (2009). *Espectrometría y dosimetría de neutrones usando NSDAAN*. Proceedings of the XI International Symposium and XXI National Congress on Solid State Dosimetry. Pp. 1-13.
- Ortiz-Rodríguez JM, Martínez-Blanco MR, Gallego E & Vega-Carrillo HR. (2009). *Redes Neuronales Evolutivas: Una nueva alternativa para la espectrometría de neutrones*. Proceedings of the XI International Symposium and XXI National Congress on Solid State Dosimetry. Pp. 1-13.
- Ortiz-rodríguez JM, Vega-Carrillo HR, Viramontes JMC & Martínez-Blanco MR. (2013). *ROBUST DESIGN OF ARTIFICIAL NEURAL NETWORKS ROBUST DESIGN OF ARTIFICIAL NEURAL NETWORKS METHODOLOGY IN NEUTRON SPECTROMETRY METHODOLOGY IN NEUTRON SPECTROMETRY*. INTECH Open Access Publisher.
- Ortiz-Rodríguez JM, Martínez-Blanco MR & Vega-Carrillo HR. (2006). *Diseño Robusto de Redes Neuronales Artificiales*. Memorias del Encuentro de Investigación en Ingeniería Eléctrica (ENINVIE 2006): 295-300
- Reyes-Alfaro A, Ortiz-Rodríguez JM, Reyes-Haro A, Castañeda-Miranda R, Solis-Sánchez LO & Vega-Carrillo HR. (2014). *Optimización de Redes Neuronales Artificiales para la reconstrucción del espectro de neutrones y sus dosis equivalentes*. Proceedings of the ISSSD 2014: 475-494.
- Valencia Reyes MA, Yáñez Márquez C & Sánchez Fernández LP. [En línea]. *Algoritmo Backpropagation para Redes Neuronales: Conceptos y aplicaciones*. <<http://www.repositoriodigital.ipn.mx/handle/123456789/8628>>. (2006). Instituto Politécnico Nacional. [Consulta: Febrero 2016].
- Vega-Carrillo HR, Hernández-Dávila VM, Manzanares-Acuña E. (2003). *Reconstrucción de Espectros de Neutrones Mediante Redes Neuronales*. Memorias del XIV Congreso Anual de la SNM/XXI Reunión Anual de la SMSR. Pp. 1-12.

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: CHI - CUADRADA - ESPECTROS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910383500-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: CHI - CUADRADA - DOSIS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910394700-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: CHI - DE - DOSIS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910371700-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: CHI - DE - ESPECTROS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910361600-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: CHI - GENERAL

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910350700-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: CORRELACION - DOSIS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910323800-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES:

CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO
CORRELACION - ESPECTROS

TITULO:

RAMA:

PROGRAMAS DE COMPUTACION

TITULARES:

CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910311600-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: CORRELACION

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910334900-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: DESEMPEÑO

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910405100-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: GRANN

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910425200-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: MATRIZ-ENTRENAMIENTO-PRUEBA

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910415200-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: MINIMOS-CUADRADOS-DOSIS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910282600-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: MINIMOS-CUADRADOS-ESPECTROS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910264700-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: MINIMOS-CUADRADOS-ESPECTROS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910264700-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: MINIMOS-CUADRADOS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910295800-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: PORTADA

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910252000-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: CHI - CUADRADA - ESPECTROS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910383500-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: CHI - CUADRADA - DOSIS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910394700-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: CHI - DE - DOSIS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910371700-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: CHI - DE - ESPECTROS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910361600-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: CHI - GENERAL

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910350700-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: CORRELACION - DOSIS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910323800-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES:

CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO
CORRELACION - ESPECTROS

TITULO:

PROGRAMAS DE COMPUTACION

RAMA:

TITULARES:

CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro:

03-2016-080910311600-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: CORRELACION

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910334900-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: DESEMPEÑO

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910405100-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: GRANN

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910425200-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: MATRIZ-ENTRENAMIENTO-PRUEBA

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910415200-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: MINIMOS-CUADRADOS-DOSIS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910282600-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: MINIMOS-CUADRADOS-ESPECTROS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910264700-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: MINIMOS-CUADRADOS-ESPECTROS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910264700-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: MINIMOS-CUADRADOS

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910295800-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: PORTADA

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910252000-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: SIMULACION - DE - RED

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910232700-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

CERTIFICADO

Registro Público del Derecho de Autor

Para los efectos de los artículos 13, 162, 163 fracción I, 164 fracción I, 168, 169, 209 fracción III y demás relativos de la Ley Federal del Derecho de Autor, se hace constar que la **OBRA** cuyas especificaciones aparecen a continuación, ha quedado inscrita en el Registro Público del Derecho de Autor, con los siguientes datos:

AUTORES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

TITULO: SIMULACION - DE - RED

RAMA: PROGRAMAS DE COMPUTACION

TITULARES: CASTAÑEDA MIRANDA RODRIGO
CASTAÑEDA SANCHEZMIRANDA VICTOR HUGO
MARTINEZ BLANCO MA. DEL ROSARIO
ORTIZ RODRIGUEZ JOSE MANUEL
SOLIS SANCHEZ CUIS OCTAVIO

Con fundamento en lo establecido por el artículo 168 de la Ley Federal del Derecho de Autor, las inscripciones en el registro establecen la presunción de ser ciertos los hechos y actos que en ellas consten, salvo prueba en contrario. Toda inscripción deja a salvo los derechos de terceros. Si surge controversia, los efectos de la inscripción quedarán suspendidos en tanto se pronuncie resolución firme por autoridad competente.

Con fundamento en los artículos 2, 208, 209 fracción III y 211 de la Ley Federal del Derecho de Autor; artículos 64, 103 fracción IV y 104 del Reglamento de la Ley Federal del Derecho de Autor; artículos 1, 3 fracción I, 4, 8 fracción I y 9 del Reglamento Interior del Instituto Nacional del Derecho de Autor, se expide el presente certificado.

Número de Registro: 03-2016-080910232700-01

México D.F., a 11 de agosto de 2016

EL DIRECTOR DEL REGISTRO PÚBLICO DEL DERECHO DE AUTOR

JESUS PARETS GOMEZ



SECRETARÍA DE CULTURA
INSTITUTO NACIONAL DEL
DERECHO DE AUTOR
DIRECCIÓN DEL REGISTRO
PÚBLICO
DEL DERECHO DE AUTOR

Currículum Vitae

CONSEJO NACIONAL DE CIENCIA Y TECNOLOGIA

MARTÍNEZ BLANCO, MA. DEL
ROSARIO

CURRICULUM VITAE UNICO

DATOS PERSONALES

No. CVU 241916
Fecha de Nacimiento 22 de septiembre de 1976
Estado Civil Unión Libre
Lugar de Nacimiento ZACATECAS, México
Nacionalidad MEXICANO
Género FEMENINO

Dirección Andador Santa María 4, GUADALUPE, ZACATECAS, México
Ciudad: Guadalupe, C.P.: 98609

IDENTIFICACIONES

México CURP: MABR760922MZSRLS02 *
RFC: MABR760922RS1

CORREO

CASA: mrosariomb@yahoo.com.mx *

TELEFONO

CELULAR: (052) 492.4921126493.
CASA: (052) 492.9221969. *

DESEMPEÑO PROFESIONAL

ADSCRIPCION ACTUAL

02/2013 - _____ INST. DE EDU. SUP. PUBLICAS, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" /
; UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA,

EXPERIENCIA LABORAL

04/2002 - 01/2004
; Empresa , NO ESPECIFICADO, GERENTE, NO ESPECIFICADO, , , , ,

PRODUCCION CIENTIFICA

ARTICULOS

- 2012 ; NSDUAZ unfolding package for neutron spectrometry and dosimetry with Bonner spheres, Vega-Carrillo, H.R.; Ortiz-Rodríguez, J.M: and Martínez-Blanco, M.R., Applied Radiation and Isotopes, Vol.71, Pag.87-91, Revistas Indizadas ,
- 2011 ; Neutron spectrometry using artificial neural networks for a bonner sphere spectrometer with a 3He detector, J.M. Ortiz-Rodríguez, M.R. Martínez-Blanco, H.R. Vega-Carrillo, E.Gallego-Díaz, A. Lorente Fillol, R. Méndez-Villafañe, J.M. los Arcos Merino, J.E. Guerrero Araque, Revista Mexicana de Física, Vol.57, Pag.69-71, Revistas Indizadas ,
- 2011 ; Performance of artificial neural networks and genetical evolved artificial neural networks unfolding techniques, J.M. Ortiz-Rodríguez, M.R. Martínez-Blanco, H.R. Vega-Carrillo, E.Gallego-Díaz, A. Lorente Fillol, R. Méndez-Villafañe, J.M. los Arcos Merino, J.E. Guerrero Araque, Revista Mexicana de Física, Vol.57, Pag.89-92, Revistas Indizadas ,
- 2010 ; Different spectra with the same neutron source, Vega-Carrillo, H.R.; Ortiz-Rodríguez, J.M.; Hernández-Dávila, V.M.; Martínez-Blanco, M.R.; Hernández-Almaraz, B.; Ortiz-Hernández, A.; Mercado, G.A., Revista Mexicana de Física, Vol.51, Pag.35-39, Revistas Indizadas ,
- 2010 ; ANN in spectrometry and neutron dosimetry, Vega-Carrillo H.R., Ortiz-Rodríguez J.M., Martínez-Blanco M.R., and Hernández-Dávila V.M., American Institute of Physics Proccedings, Vol.1310, Pag.12-17, Revistas Indizadas ,
- 2009 ; A computational tool design for evolutionary artificial neural networks in neutron spectrometry and dosimetry, Ortiz-Rodríguez, J.M.; Martínez-Blanco, M.R.; Vega-Carrillo, H.R., IEEE Computer Society, Vol.1, Pag.113-118, Revistas Indizadas ,
- 2009 ; Evolutionary Artificial Neural Networks in neutron dosimetry, Ortiz-Rodríguez José Manuel, Martínez-Blanco Ma. del Rosario, Gallego Eduardo and Vega-Carrillo, Héctor René, American Nuclear Society, Vol.1, Pag.1-2, Revistas Indizadas ,
- 2009 ; NSDann: Espectrometría y dosimetría de neutrones, Martínez-Blanco M.R., Ortiz-Rodríguez J.M. and Vega-Carrillo H.R., México Nuclear, Vol.9, Pag.19-29, Revistas Arbitradas ,
- 2009 ; Spectra and dose with ANN of 252Cf, 241AmBe and 239PuBe, Vega-Carrillo H.R., Martínez-Blanco M.R., Hernández-Dávila V.M. and Ortiz-Rodríguez J.M., Journal of Radioanalytical and Nuclear Chemistry, Vol.281, Pag.615-618, Revistas Indizadas ,
- 2009 ; NSDann, a LabVIEW tool for neutron spectrometry and dosimetry based on the RDANN methodology, Martínez-Blanco, M.R.; Ortiz-Rodríguez, J.M.; Vega-Carrillo, H.R., IEEE Computer Society, Vol.1, Pag.131-136, Revistas Indizadas ,
- 2008 ; Artificial neural networks modeling evolved genetically, a new approach applied in neutron spectrometry and dosimetry research areas, Ortiz-Rodríguez J.M., Martínez-Blanco M.R., Gallego E. and Vega-Carrillo H.R., IEEE Computer Society, Vol.1, Pag.387-392, Revistas Indizadas ,
- 2008 ; A new computer tool based on ANN technology, applied in neutron spectrometry and dosimetry research areas, Martínez-Blanco M.R., Ortiz-Rodríguez J.M. and Vega-Carrillo H.R., IEEE Computer Society, Vol.1, Pag.189-194, Revistas Indizadas ,
- 2006 ; Robust design of artificial neural networks applying the Taguchi methodology and DoE., Ortiz-Rodríguez J.M., Martínez-Blanco M.R., Vega-Carrillo H.R., IEEE Computer Society, Vol.1, Pag.131-136, Revistas Indizadas ,

LIBROS

- 2014 ; NSDANN, UN CÓDIGO PARA ESPECTROMETRÍA Y DOSIMETRÍA NEUTRÓNICAS, BASADO EN LA TECNOLOGÍA DE REDES NEURONALES ARTIFICIALES, José Manuel Ortiz-Rodríguez Ma. del Rosario Martínez-Blanco Héctor René Vega-Carrillo, EDITORIAL ACADÉMICA ESPAÑOLA, ISBN978-3-659-06907-3
- 2014 ; ESPECTROMETRÍA Y DOSIMETRÍA DE NEUTRONES: UNA NUEVA GENERACIÓN DE HERRAMIENTAS TECNOLÓGICAS, José Manuel Ortiz-Rodríguez Ma. del Rosario Martínez-Blanco Héctor René Vega-Carrillo, EDITORIAL ACADÉMICA ESPAÑOLA, ISBN978-3-659-07040-2
- 2013 ; DISEÑO DE ARQUITECTURAS ÓPTIMAS DE REDES NEURONALES ARTIFICIALES, EMPLEANDO UNA METODOLOGÍA DE DISEÑO ROBUSTO EN ESPECTROMETRÍA NEUTRÓNICA, José Manuel Ortiz-Rodríguez Ma. del Rosario Martínez-Blanco Héctor René Vega-Carrillo, EDITORIAL ACADÉMICA ESPAÑOLA, ISBN978-3-659-06523-1
- 2013 ; ESPECTROMETRÍA Y DOSIMETRÍA DE NEUTRONES CON REDES NEURONALES ARTIFICIALES, DISEÑO DE UNA ARQUITECTURA ÓPTIMA DE RED, José Manuel Ortiz-Rodríguez Ma. del Rosario Martínez-Blanco Héctor René Vega-Carrillo, EDITORIAL ACADÉMICA ESPAÑOLA, ISBN978-3-659-06693-2

CAPITULOS DE LIBROS

- 2016 ; Generalized regression Artificial Neural Networks with Application in Neutron Spectrometry, Artificial Neural Networks, JOAO LUIS GARCIA ROSA, INTECH, Vol. , Pags. , José Manuel Ortiz-Rodríguez, Ma. del Rosario Martínez-Blanco, Victor Hugo Castañeda Miranada, Gerardo Ornelas Vargas, Hector Alonso Guerrero Osuna, Luis Octavio Solís Sanchez, Rodrigo Castañeda Miranda, Jorge Issac Galvan Tejada, Carlos Eric Galvan Tejada, Jose Maria Celaya Padilla, Margarita Martínez Fierro, Idalia Garza Veloz, Roberto Mendez Villafañe, Eduardo Gallego, Marco Aurelio de Sousa Lacerda and Héctor René Vega-Carrillo
- 2013 ; ROBUT DESIGN OF ARTIFICIAL NEURAL NETWORKS METHODOLOGY IN NEUTRON SPECTROMETRY, Artificial Neural Networks, Architectures and applications INTECH, KENJI SUZUKI, Vol. , Pags. 264, José Manuel Ortiz-Rodríguez, Ma. del Rosario Martínez-Blanco, Héctor René Vega-Carrillo
- 2011 ; EVOLUTIONARY ARTIFICIAL NEURAL NETWORKS IN NEUTRON SPECTROMETRY, Artificial Neural Networks - Application INTECH, CHI LEUNG PATRICK HUI, Vol. , Pags. 598, José Manuel Ortiz-Rodríguez, Ma. del Rosario Martínez-Blanco, Héctor René Vega-Carrillo

PARTICIPACION EN CONGRESOS

- 2016 ; A Study Using the Robust Design of Artificial Neural Networks Methodology in Neutron Spectrometry, Extranjero, 2016 IEEE International Conference on Industrial Technology (ICIT2016), ORTIZ-RODRIGUEZ J.M. MARTINEZ-BLANCO M.R. ORNELAS-VARGAS G. GUERRERO-OZUNA H.A. MENDOZA-HASSO J.H SOLIS-SANCHEZ L.O. CASTAÑEDA-MIRANDA R. VEGA-CARRILLO H.R. , Taiwán, Provincia China ,
- 2016 ; Identification and Evaluation on Diabetic Foot Injury by Computer Vision, Extranjero, 2016 IEEE International Conference on Industrial Technology (ICIT2016), LUIS O SOLIS-SANCHEZ JOSE MANUEL ORTIZ-RODRIGUEZ RODRIGO CASTAÑEDA-MIRANDA GERARDO ORNELAS-VARGAS MARIA DEL ROSARIO MARTINEZ-BLANCO JORGE ISAAC GALVAN-TEJADA CARLOS ERIK GALVAN-TEJADA JOSE MARIA CELAYA PADILLA , México ,
- 2015 ; A comparison of backpropagation and generalized regression neural networks performance in neutron spectrometry, Extranjero, XV International Symposium os Solid State Dosimetry, JOSE MANUEL ORTIZ-RODRIGUEZ MA. DEL ROSARIO MARTINEZ-BLANCO LUIS OCTAVIO SOLÍS-SÁNCHEZ RODRIGO CASTAÑEDA-MIRANDA HÉCTOR RENÉ VEGA-CARRILLO , México ,
- 2015 ; A neutron spectrum unfolding code based on generalized regression artificial neural networks, Extranjero, XV International Symposium os Solid State Dosimetry, JOSE MANUEL ORTIZ-RODRIGUEZ MA. DEL ROSARIO MARTINEZ-BLANCO LUIS OCTAVIO SOLÍS-SÁNCHEZ RODRIGO CASTAÑEDA-MIRANDA HÉCTOR RENÉ VEGA-CARRILLO , México ,
- 2015 ; Monitor de área para neutrones, Nacional, IV Congreso de la Federación Mexicana de Organizaciones de Física Médica FMOFM, H.R. VEGA-CARRILLO J.M. ORTIZ R. M.R. MARTÍNEZ B. K.A. GUZMÁN V.M. HERNÁNDEZ D. , México ,
- 2015 ; NSDann, a neutron spectrum unfolding code based on artificial neural networks technology, Extranjero, XI International Symposium on Radiation Physics, J.M.ORTIZ-RODRÍGUEZ A. REYES ALFARO M.R. MARTÍNEZ-BLANCO G.ORNELAS-VARGAS R.CASTAÑEDA-MIRANDA L.O.SOLIS-SANCHEZ H.R. VEGA-CARRILLO , México ,
- 2015 ; Test and validation of the neutron spectra unfolding code NSDUAZ, Extranjero, XI International Symposium on Radiation Physics, J.M.ORTIZ-RODRÍGUEZ M.R. MARTÍNEZ-BLANCO G.ORNELAS-VARGAS R.CASTAÑEDA-MIRANDA L.O.SOLIS-SANCHEZ H.R. VEGA-CARRILLO , México ,
- 2014 ; Generalized Regression Neural Networks in Neutron Spectrometry Using Two Bonner Spheres as Entrance Data, Extranjero, X International Symposium on Radiation Physics, ORTIZ- RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. SOLÍS-SÁNCHEZ L.O. CASTAÑEDA-MIRANDA R. VEGA-CARRILLO H.R. , México ,
- 2014 ; NSDANN, a Neutron Spectrum Unfolding Code Based on Artificial Neural Networks Technology, Extranjero, X International Symposium on Radiation Physics, ORTIZ-RODRÍGUEZ J.M. REYES-HARO A. REYES-ALFARO A. MARTÍNEZ-BLANCO M.R. SOLÍS-SÁNCHEZ L.O. CASTAÑEDA-MIRANDA R. VEGA-CARRILLO H.R. , México ,
- 2014 ; Test and Validation of an Iterative Code for Neutron Spectrometry, Extranjero, X International Symposium on Radiation Physics, ORTIZ- RODRÍGUEZ J.M. REYES-HARO A. REYES-ALFARO A. MARTÍNEZ-BLANCO M.R. SOLÍS-SÁNCHEZ L.O. CASTAÑEDA-MIRANDA R. VEGA-CARRILLO H.R. , México ,
- 2011 ; NSDUAZ unfolding package for neutron spectrometry and dosimetry with Bonner spheres, Extranjero, Proceedings of the XII International Symposium on Solid State Dosimetry, VEGA-CARRILLO, H.R. ORTIZ-RODRIGUEZ, J.M. MARTINEZ-BLANCO, M.R. , México ,
- 2010 ; Cálculo del error producido por las lecturas de conteo en la espectrometría neutrónica por medio de esferas Bonner y la distribución de poisson, Nacional, 1^o Seminario de Investigación UAA, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. LOS ARCOS-MERINO J.M. MÉNDEZ-VILLAFÁÑE R. , México ,

- 2010 ; Comparación del espectro de neutrones de un detector de ^3He obtenido con dos códigos de deconvolución, Nacional, 11^o Seminario de Investigación UAA, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. MÉNDEZ-VILLAFANE R. , México ,
- 2010 ; Comparing the neutron spectra unfolding features using two codes, Nacional, VI International Symposium on Radiation Physics, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. GALLEGU E. LORENTE-FILLOL A. MÉNDEZ-VILLAFANE R. LOS ARCOS-MERINO J.M. GUERRERO-ARAQUE J.E. , México ,
- 2010 ; Espectrometría y dosimetría neutrónicas con redes neuronales artificiales para un detector de ^3He , Nacional, 11^o Seminario de Investigación UAA, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. MÉNDEZ-VILLAFANE R. , México ,
- 2010 ; Neutron spectrometry using artificial neural networks for a Bonner sphere spectrometer with a ^3He detector, Nacional, VI International Symposium on Radiation Physics, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. GALLEGU E. LORENTE-FILLOL A. MÉNDEZ-VILLAFANE R. LOS ARCOS-MERINO J.M. GUERRERO-ARAQUE J.E. , México ,
- 2010 ; Performance of artificial neural networks and genetical evolved artificial neural networks unfolding techniques, Nacional, VI International Symposium on Radiation Physics, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. GALLEGU E. LORENTE-FILLOL A. MÉNDEZ-VILLAFANE R. LOS ARCOS-MERINO J.M. GUERRERO-ARAQUE J.E. , México ,
- 2010 ; User-friendly interface for run MCNP code for radiation physics, Nacional, VI International Symposium on Radiation Physics, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. GALLEGU E. LORENTE-FILLOL A. MÉNDEZ-VILLAFANE R. LOS ARCOS-MERINO J.M. GUERRERO-ARAQUE J.E. , México ,
- 2010 ; ^{241}Am -Be source term simulation with Monte Carlo methods, Nacional, VI International Symposium on Radiation Physics, MÉNDEZ-VILLAFANE R. GUERRERO-ARAQUE J.E. GALLEGU E. LORENTE-FILLOL A. TORE C. ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. , México ,
- 2009 ; Diseño de una herramienta de cómputo para la espectrometría y dosimetría de neutrones con redes neuronales evolutivas, Nacional, 10^o seminario de investigación UAA, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. , México ,
- 2009 ; Diseño de una herramienta de cómputo para la espectrometría y dosimetría de neutrones por medio de redes neuronales evolutivas, Nacional, XX Congreso Anual de la SNM, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. GALLEGU E. VEGA-CARRILLO H.R. , México ,
- 2009 ; Espectrometría de las fuentes de neutrones de ^{239}Pu , ^{252}Cf y ^{241}Am por medio de NSDUAZ, Extranjero, XI International Symposium / XXI National Congress on Solid State Dosimetry, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. GALLEGU E. VEGA-CARRILLO H.R. , México ,
- 2009 ; Espectrometría y dosimetría de neutrones en LINACs utilizando NSDANN, Extranjero, XI International Symposium / XXI National Congress on Solid State Dosimetry, ORTIZ-RODRÍGUEZ J.M. VEGA-CARRILLO H.R. , México ,
- 2009 ; Evolutionary artificial neural networks in neutron dosimetry, Extranjero, American Nuclear Society: 2009 Winter Meeting. Washington, D.C., EEUU, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. GALLEGU E. VEGA-CARRILLO H.R. , México ,
- 2009 ; NSDann espectrometría y dosimetría de neutrones por medio de redes neuronales artificiales, Nacional, 10^o seminario de investigación UAA, ORTIZ-RODRÍGUEZ J.M. VEGA-CARRILLO H.R. , México ,
- 2009 ; Redes neuronales artificiales genéticas: una nueva alternativa para la espectrometría de neutrones, Extranjero, XI International Symposium / XXI National Congress on Solid State Dosimetry, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. GALLEGU E. VEGA-CARRILLO H.R. , México ,
- 2009 ; Una nueva herramienta de cómputo para la espectrometría y dosimetría de neutrones, Nacional, XX Congreso Anual de la SNM, ORTIZ-RODRÍGUEZ J.M. VEGA-CARRILLO H.R. , México ,
- 2009 ; Una nueva propuesta para dosimetría neutrónica por medio de métodos iterativos, Nacional, 10^o seminario de investigación UAA, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. , México ,
- 2008 ; A neutron spectrometry and dosimetry computer tool based on ANN, Extranjero, 12th International Congress of the International Radiation Protection Association (IRPA), ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. GALLEGU E. VEGA-CARRILLO H.R. , Argentina ,
- 2008 ; Diseño de redes neuronales artificiales por medio de algoritmos genéticos, aplicadas en la espectrometría y dosimetría de neutrones, Nacional, XII Jornadas de Investigación UAZ, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. , México ,
- 2008 ; Diseño de redes neuronales artificiales por medio de algoritmos genéticos, aplicadas en la espectrometría y dosimetría de neutrones, Nacional, 9o seminario de investigación UAA, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. , México ,
- 2008 ; Diseño de una interfase gráfica de usuario, para la espectrometría y dosimetría de neutrones, basado en redes neuronales artificiales, Nacional, XII Jornadas de Investigación UAZ, ORTIZ-RODRÍGUEZ J.M. VEGA-CARRILLO H.R. , México ,

- 2008 ; Espectrometría y dosimetría de neutrones por medio de redes neuronales evolutivas, Nacional, Congreso Anual de la SNM, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. , México ,
- 2008 ; Neutron spectrometry and dosimetry based on a new approach called genetic artificial neural networks, Extranjero, 12th International Congress of the International Radiation Protection Association (IRPA), ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. GALLEGO E. VEGA-CARRILLO H.R. , Argentina ,
- 2008 ; Solución de problemas en ingeniería por medio de algoritmos genéticos, descripción de un ejemplo sencillo de optimización, Nacional, XII Jornadas de Investigación UAZ, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. , México ,
- 2007 ; ANN knowledge extraction at Matlab environment, for neutron spectrometry and simultaneous dosimetry, Nacional, XI Jornadas de Investigación UAZ, ORTIZ-RODRÍGUEZ J.M. VEGA-CARRILLO H.R. MARTÍNEZ-BLANCO M.R. , México ,
- 2007 ; ANN optimization by means of RDANN and RSM methodologies, Nacional, XI Jornadas de Investigación UAZ, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. , México ,
- 2007 ; Development of a new software tool, based on ANN technology, in neutron spectrometry and dosimetry research, Extranjero, X International Symposium / XX National Congress on Solid State Dosimetry, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. , México ,
- 2007 ; Genetic artificial neural networks (GANN) modeling, Nacional, XI Jornadas de Investigación UAZ, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. , México ,
- 2006 ; A proposal to order the neutron data set in neutron spectrometry using the RDANN methodology, Extranjero, IX International Symposium / XIX National Meeting on Solid State Dosimetry, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. , México ,
- 2006 ; Diseño de neuro-hardware, Nacional, Encuentro de Investigación en Ingeniería Eléctrica (ENINVIE-UAZ 2006), ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. , México ,
- 2006 ; Diseño robusto de redes neuronales artificiales, Nacional, Encuentro de Investigación en Ingeniería Eléctrica (ENINVIE-UAZ 2006), ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. , México ,
- 2006 ; Espectrometría de neutrones y cálculo de dosis equivalentes, aplicando la metodología de diseño robusto de redes neuronales artificiales, Nacional, Encuentro de Investigación en Ingeniería Eléctrica (ENINVIE-UAZ 2006), ORTIZ-RODRÍGUEZ J.M. VEGA-CARRILLO H.R. , México ,
- 2006 ; Neutron spectrometry and dosimetry by means of Bonner spheres system and artificial neural networks applying robust design of artificial neural networks, Extranjero, Primer Congreso Americano del IRPA / XXIV Reunión Anual de la SMSR / XVII Congreso Anual de la SNM, ORTIZ-RODRÍGUEZ J.M. VEGA-CARRILLO H.R. , México ,
- 2006 ; Neutron spectrometry and dosimetry by means of bonner spheres system and artificial neural networks applying robust design of artificial neural networks, Extranjero, IX International Symposium / XIX National Meeting on Solid State Dosimetry, ORTIZ-RODRÍGUEZ J.M. VEGA-CARRILLO H.R. , México ,
- 2006 ; Problemas críticos en el diseño y construcción de redes neuronales, en la espectrometría de neutrones, utilizando la metodología de diseño robusto de redes neuronales artificiales, Extranjero, Primer Congreso Americano del IRPA / XXIV Reunión Anual de la SMSR / XVII Congreso Anual de la SNM, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. , México ,
- 2006 ; RDANN a new methodology to solve the neutron spectra unfolding problem, Extranjero, IX International Symposium / XIX National Meeting on Solid State Dosimetry, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. , México ,
- 2006 ; Robust design of artificial neural networks applying the Taguchi methodology and DoE, Extranjero, Congreso de Electrónica, Robótica y Mecánica Automotriz CERMA 2006, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. VEGA-CARRILLO H.R. , México ,
- 2005 ; Diseño robusto de redes neuronales artificiales multicapa de propagación hacia delante, con el algoritmo de propagación inversa, en la reconstrucción de espectros de neutrones, Nacional, IX Jornadas de Investigación UAZ, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. ARTEAGA-ARTEAGA T. VEGA-CARRILLO H.R. HERNÁNDEZ-DÁVILA V.M. MANZANARES-ACUÑA E. , México ,
- 2005 ; Reconstrucción de espectros de neutrones usando redes neuronales a partir del sistema espectrométrico de esferas de Bonner, Extranjero, Reconstrucción de espectros de neutrones usando redes neuronales a partir del sistema espectrométrico de esferas de Bonner, ORTIZ-RODRÍGUEZ J.M. MARTÍNEZ-BLANCO M.R. ARTEAGA-ARTEAGA T. VEGA-CARRILLO H.R. HERNÁNDEZ-DÁVILA V.M. MANZANARES-ACUÑA E. , México ,

FORMACION ACADEMICA

NIVELES/GRADOS ACADEMICOS

- ; DOCTORADO, DOCTORADO EN INGENIERÍA Y TECNOLOGÍA APLICADA, , UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, México , ZACATECAS , INST. DE EDU. SUP. PUBLICAS , Diseño de herramientas tecnológicas basadas en redes neuronales artificiales aplicadas en espectrometría y dosimetría neutrónica
- 29/06/2009 ; MAESTRIA, MAESTRÍA EN CIENCIAS NUCLEARES CON OPCIÓN TERMINAL EN INSTRUMENTACIÓN NUCLEAR, 6394558, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / CENTRO REGIONAL DE ESTUDIOS NUCLEARES, México , ZACATECAS , INST. DE EDU. SUP. PUBLICAS , NSDann: una herramienta de cómputo para la espectrometría y dosimetría de neutrones basada en RNA
- 10/02/2006 ; LICENCIATURA, INGENIERO EN COMUNICACIONES Y ELECTRÓNICA, 5187727, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / AREA ACADEMICA DE INGENIERIA Y TECNOLOGIA, México , ZACATECAS , INST. DE EDU. SUP. PUBLICAS , Espectrometría de neutrones y cálculo de dosis equivalentes aplicando la metodología de diseño robusto de redes neuronales

FORMACION DE RECURSOS HUMANOS

DOCENCIA

- 01/2016 - 05/2016 Seminario de investigación, desarrollo tecnológico e innovación I, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,MAESTRIA
- 01/2016 - 05/2016 Informática IV, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,
- 01/2016 - 05/2016 Informática II, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,LICENCIATURA
- 01/2016 - 05/2016 Informática III, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,LICENCIATURA
- 01/2016 - 05/2016 Computación aplicada, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,MAESTRIA
- 08/2015 - 11/2015 Matemáticas II, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,LICENCIATURA
- 08/2015 - 11/2015 Matemáticas I, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,LICENCIATURA
- 08/2015 - 11/2015 Métodos numéricos, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,LICENCIATURA
- 08/2015 - 11/2015 Electromagnetismo y óptica, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,LICENCIATURA
- 08/2015 - 11/2015 Cálculo II, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,LICENCIATURA
- 08/2015 - 11/2015 Informática III, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,LICENCIATURA
- 08/2015 - 11/2015 cálculo I, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,LICENCIATURA
- 08/2015 - 11/2015 Computación aplicada, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,MAESTRIA
- 08/2015 - 11/2015 Seminario de investigación, desarrollo tecnológico e innovación I, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,MAESTRIA
- 08/2015 - 11/2015 Matemáticas III, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,LICENCIATURA
- 01/2015 - 05/2015 Cálculo I, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,LICENCIATURA
- 01/2015 - 05/2015 Cálculo II, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,LICENCIATURA
- 01/2015 - 05/2015 Matemáticas I, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,LICENCIATURA
- 01/2015 - 05/2015 Matemáticas II, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, ,LICENCIATURA

- 01/2015 - 05/2015 Informática II, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA ; SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, LICENCIATURA
- 01/2015 - 05/2015 Computación aplicada, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA ; SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, MAESTRIA
- 08/2014 - 11/2014 Laboratorio de electrónica I, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO ; GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, LICENCIATURA
- 08/2014 - 11/2014 Métodos numéricos, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA ; SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, LICENCIATURA
- 08/2014 - 11/2014 Informática II, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA ; SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, LICENCIATURA
- 08/2014 - 11/2014 Matemáticas I, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA ; SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, LICENCIATURA
- 08/2014 - 11/2014 Cálculo I, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, LICENCIATURA
- 01/2014 - 05/2014 Cálculo I, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, LICENCIATURA
- 01/2014 - 05/2014 Laboratorio de electrónica I, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO ; GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, LICENCIATURA
- 01/2014 - 05/2014 Matemáticas I, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA ; SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, LICENCIATURA
- 08/2013 - 11/2013 Laboratorio de electrónica I, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO ; GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, LICENCIATURA
- 08/2013 - 11/2013 Laboratorio de electrónica I, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO ; GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, LICENCIATURA
- 01/2013 - 05/2013 Teoría electromagnética, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO ; GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, LICENCIATURA
- 01/2013 - 05/2013 Teoría electromagnética, Tiempo en Horas (60) UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO ; GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA, LICENCIATURA

TESIS DIRIGIDAS

; , NO ESPECIFICADO, TECNICO SUPERIOR (PROFESIONAL ASOCIADO), México ,

INVESTIGACION CIENTIFICA Y TECNOLOGICA

PROYECTOS DE INVESTIGACIÓN

- 08/2015 - 07/2018 Proyecto de Investigación , Estudio, análisis, diseño y optimización de arquitecturas de redes neuronales ; artificiales en la espectrometría y dosimetría de neutrones, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA
Empresas Participantes : SERVICIO DE RADIACIONES APLICADAS A LA SALUD , DEPARTAMENTO DE INGENIERÍA NUCLEA , LABORATORIO PRIMARIO DE PATRONES NEUTRÓNICOS , DEPARTAMENTO DE RADIOTERAPIA Y SEGURIDAD RADIOLÓGICA , INSTITUTO NACIONAL DE INVESTIGACIONES NUCLEARES
Investigadores Participantes : ORTIZ RODRÍGUEZ JOSÉ MANUEL
Becarios Participantes : ARTEAGA ARTEAGA TARCICIO , MARTÍNEZ BLANCO MA. DEL ROSARIO , CASTAÑEDA MIRANDA VÍCTOR HUGO

GRUPOS DE INVESTIGACION

09/2011 ; Laboratorio de metrología de radiaciones ionizantes CIEMAT, NO ESPECIFICADO , , HÉCTOR RENÉ VEGA-CARRILLO , JOSÉ MANUEL ORTIZ-RODRÍGUEZ , MA. DEL ROSARIO MARTÍNEZ-BLANCO , MIGUEL EMBID SEGURA , ROBERTO MÉNDEZ VILLAFañE ,NO ESPECIFICADO

;DESARROLLOS TECNOLOGICOS

- 06/2010 - 12/2010 NSDUAZ, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA ,UAEN-UAZ, LMRI-CIEMAT Y DIN-UPM ESPAÑA MARTÍNEZ BLANCO MA. DEL ROSARIO, VEGA CARRILLO HÉCTOR RENÉ, GALLEGU DÍAZ EDUARDO, LORENTE FILLOL ALFREDO, MÉNDEZ VILLAFañE ROBERTO, LOS ARCOS MERINO JOSÉ MARÍA, GUERRERO ARAQUE JORGE EDUARDO, ORTIZ RODRÍGUEZ JOSÉ MANUEL

- 07/2010 - 12/2010 NSDEANN, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA ; DE INGENIERÍA ELÉCTRICA ,AUEN-UAZ MÉXICO, LMRI-CIEMAT Y DIN-UPM ESPAÑA MARTÍNEZ BLANCO MA. DEL ROSARIO, VEGA CARRILLO HÉCTOR RENÉ, ORTIZ RODRÍGUEZ JOSÉ MANUEL, GALLEGU DÍAZ EDUARDO, LORENTE FILLLO ALFREDO, MÉNDEZ VILLAFañE ROBERTO, LOS ARCOS MERINO JOSÉ MARÍA, GUERRERO ARAQUE JORGE EDUARDO
- 01/2009 - 07/2010 TBGANN O_1, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA ; DE INGENIERÍA ELÉCTRICA ,UAEN-UAZ MÉXICO, LMRI-CIEMAR Y DIN-UPM ESPAÑA ORTIZ RODRIGUEZ JOSE MANUEL, MARTÍNEZ BLANCO MA. DEL ROSARIO, VEGA CARRILLO HÉCTOR RENÉ, MÉNDEZ VILLAFañE ROBERTO, GALLEGU DÍAZ EDUARDO, LORENTE FILLLO ALFREDO, LOS ARCOS MERINO JOSÉ MARÍA, GUERRERO ARAQUE JORGE EDUARDO
- 10/2009 - 03/2010 NSDANN3HE, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA ; DE INGENIERÍA ELÉCTRICA ,LMRI-CIEMAT ESPAÑA ORTIZ RODRÍGUEZ JOSÉ MANUEL, MARTÍNEZ BLANCO MA. DEL ROSARIO, VEGA CARRILLO HÉCTOR RENÉ, GALLEGU DÍAZ EDURADO, LORENTE FILLLO ALFREDO, MÉNDEZ VILLAFañE ROBERTO, LOS ARCOS MERINO JOSÉ MARÍA, GUERRERO ARAQUE EDUARDO
- 10/2009 - 03/2010 GENERACIÓN AUTOMATIZADA DE MATRICES DE ENTRENAMIENTO DE REDES NEURONALES PARA ; ESPECTROMETRÍA NEUTRÓNICA, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA ,AUEN-UAZ MÉXICO, LMRI-CIEMAT Y DIN-UPM ESPAÑA MARTÍNEZ BLANCO MA. DEL ROSARIO, ORTIZ RODRÍGUEZ JOSÉ MANUEL, VEGA CARRILLO HÉCTOR RENÉ, GALLEGU DÍAZ EDUARDO, LORENTE FILLLO ALFREDO, MÉNDEZ VILLAFañE ROBERTO, LOS ARCOS MERINO JOSÉ MARÍA, GUERRERO ARAQUE JORGE EDUARDO
- 10/2009 - 03/2010 NSDTB3HE, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA ; DE INGENIERÍA ELÉCTRICA ,LMRI-CIEMAT ESPAÑA ORTIZ RODRÍGUEZ JOSÉ MANUEL, MARTÍNEZ BLANCO MA. DEL ROSARIO, VEGA CARRILLO HÉCTOR RENÉ, GALLEGU DÍAZ EDUARDO, MÉNDEZ VILLAFañE ROBERTO, LOS ARCOS MERINO JOSÉ MARÍA, LORENTE FILLLO ALFREDO, GUERRERO ARAQUE JORGE EDUARDO
- 10/2009 - 03/2010 NSDEANN3HE, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA ,LMRI-CIEMAT ESPAÑA ORTIZ RODRÍGUEZ JOSÉ MANUEL, MARTÍNEZ BLANCO MA. DEL ROSARIO, VEGA CARRILLO HÉCTOR RENÉ, GALLEGU DÍAZ EDUARDO, LORENTE FILLLO ALFREDO, MÉNDEZ VILLAFañE ROBERTO, LOS ARCOS MERINO JOSÉ MARÍA, GUERRERO ARAQUE EDUARDO
- 10/2009 - 03/2010 NSDUAZ3HE, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA ; DE INGENIERÍA ELÉCTRICA ,LMRI-CIEMAT ESPAÑA ORTIZ RODRÍGUEZ JOSÉ MANUEL, MARTÍNEZ BLANCO MA. DEL ROSARIO, VEGA CARRILLO HÉCTOR RENÉ, GALLEGU DÍAZ EDURDO, LORENTE FILLLO ALFREDO, MÉNDEZ VILLAFañE ROBERTO, LOS ARCOS MERINO JOSÉ MARÍA, GUERRERO ARAQUE JORGE EDUARDO
- 10/2009 - 03/2010 NSDTB, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA ,AUEN-UAZ MÉXICO, LMRI-CIEMAT Y DIN-UPM ESPAÑA ORTIZ RODRÍGUEZ JOSÉ MANUEL, MARTÍNEZ BLANCO MA. DEL ROSARIO, VEGA CARRILLO HÉCTOR RENÉ, GALLEGU DÍAS EDUARDO, LORENTE FILLLO ALFREDO, MENDEZ VILLAFañE ROBERTO, LOS ARCOS MERINO JOSÉ MARÍA, GUERRERO ARAQUE EDUARDO
- 07/2009 - 01/2010 VMCNPEX O_1, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA ,AUEN-UAZ MÉXICO, LMRI-CIEMAT Y DIN-UPM ESPAÑA ORTIZ RODRÍGUEZ JOSÉ MANUEL, MARTÍNEZ BLANCO MA. DEL ROSARIO, VEGA CARRILLO HÉCTOR RENÉ, GALLEGU DÍAZ EDUARDO, LORENTE FILLLO ALFREDO, MÉNDEZ VILLAFañE ROBERTO, LOS ARCOS MERINO JOSÉ MARÍA, GUERRERO ARAQUE JORGE EDUARDO
- 01/2008 - 05/2009 NSDANN O_1, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA ,AUEN-UAZ MÉXICO, LMRI-CIEMAT Y DIN-UPM ESPAÑA
- 07/2006 - 01/2007 VALGRAF 1_0, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA ,COMUNIDAD CIENTÍFICA DEL ÁREA NUCLEAR MARTÍNEZ BLANCO MA. DEL ROSARIO, ORTIZ RODRÍGUEZ JOSÉ MANUEL, VEGA CARRILO HÉCTOR RENÉ
- 05/2006 - 06/2006 RECONSTRUCTOR_VER_1_0, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA ,COMUNIDAD CIENTÍFICA DEL ÁREA NUCLEAR MARTÍNEZ BLANCO MA. DEL ROSARIO, ORTIZ RODRÍGUEZ JOSÉ MANUEL, VEGA CARRILLO HÉCTOR RENÉ
- 01/2005 - 03/2006 DRRNA_VER_2_14, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA ,COMUNIDAD CIENTÍFICA DEL ÁREA NUCLEAR MARTÍNEZ BLANCO MA. DEL ROSARIO, ORTIZ RODRÓGUEZ JOSÉ MANUEL, VEGA CARRILLO HÉCTOR RENÉ
- 01/2004 - 12/2005 DISEÑO ROBUSTO DE REDES NEURONALES ARTIFICIALES ENLA ESPECTROMETRÍA DE NEUTRONES, ; UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA ,COMUNIDAD CIENTÍFICA DEL ÁREA NUCLEAR ORTIZ RODRÍGIEZ JOSÉ MANUEL, MARTÍNEZ BLANCO MA. DEL ROSARIO, VEGA CARRILLO HÉCTOR RENÉ, HERNÁNDEZ DÁVILA VICTOR MARTÍN
- 06/2005 - 10/2005 DRRNA_VER_1_3, UNIVERSIDAD AUTONOMA DE ZACATECAS "FRANCISCO GARCIA SALINAS" / UNIDAD ACADEMICA DE INGENIERÍA ELÉCTRICA ,COMUNIDAD CIENTÍFICA EL ÁREA NUCLEAR MARTÍNEZ BLANCO MA. DEL ROSARIO, ORTIZ RODRÍGUEZ JOSÉ MANUEL, VEGA CARRILLO HÉCTOR RENÉ

;APOYOS CONACYT

09/2015 - 08/2016 ; 23386, Desarrollo Tecnológico , BECA
08/2008 - 06/2009 ; 220142, Formación Académica , BECA

PROPIEDAD INTELECTUAL

;DERECHOS DE AUTOR

31/03/2006 ; DRRNA_VER_1_3, 03-2006-031312574800-01 , Autor , DOCENCIA E INVESTIGACIÓN , Pública
30/06/2008 ; DRRNA Ver. 2.14, 03-2008-061611072500-01 , Autor , DOCENCIA E INVESETIAGCIÓN , Pública

;DESARROLLO DE SOFTWARE

20/12/05 ; DRRNA_VER_1_3, INVESTIGACIÓN , Pública , NO ESPECIFICADO, NO ESPECIFICADO , México
12/05/06 ; DRRNA_VER_2_4, INVESTIGACIÓN , Pública , NO ESPECIFICADO, NO ESPECIFICADO , México

DISTINCIONES Y PREMIOS

DISTINCIONES

2010 ; Mejor ponencia en mesa temática XI Seminario de Investigación México, Universidad Autónoma de Aguascalientes
2009 ; Mejor trabajo de la mesa de Ingenierías II X seminario de investigación México, Universidad Autónoma de Aguascalientes
2009 ; Mejor trabajo de la mesa de Ingenierías I X seminario de investigación México, Universidad Autónoma de Aguascalientes
2009 ; Mejor trabajo en el XX Congreso Anual de la SNM Sociedad Nuclear Mexicana México, Sociedad Nuclear Mexicana
2006 ; Mención honorífica UA Estudios Nucleares México, Universidad utónoma de Zacatecas
2006 ; 4º Lugar Socedad Nuclear Mexicana México, SOCEDAD NUCLEAR MEXICANA