



XXII Seminario de Ingeniería Biomédica
Núcleo de Ingeniería Biomédica
Facultades de Medicina e Ingeniería
UdelaR-Edición 2015

Evaluación de la utilidad de las redes neuronales artificiales en diagnósticos médicos, tomando como ejemplos de estudio las enfermedades del corazón y la nefritis aguda.

Valentina Da Silva – 5.113.011-5

Monografía vinculada a la conferencia del docente Dr. Eduardo Mizraji sobre “Las redes neuronales: de la biología a los algoritmos de clasificación” realizada el día 14 de abril de 2015.

vale9003@gmail.com

Resumen.

El objetivo de esta monografía es evaluar a las redes neuronales artificiales en el diagnóstico de enfermedades. Para esto nos basaremos en el paper *Importance of Artificial Neural Network in Medical Diagnosis disease like acute nephritis disease and heart disease*. En dicho paper dos casos son estudiados. El primer caso es la enfermedad de la nefritis aguda; los datos utilizados son los síntomas de la enfermedad. El segundo caso estudiado, son las enfermedades del corazón; los datos son tomados de las imágenes SPECT o tomografía computarizada de emisión monofotónica (en inglés *single photon emission computed tomography*). Cada paciente es clasificado en dos categorías: infectado y no infectado. La clasificación es una herramienta importante que sirve de apoyo en las decisiones de diagnóstico médico. Una red neuronal artificial de tipo *Feed-Forward Back Propagation* es utilizada como clasificador para distinguir entre una persona infectada o no en ambos casos. Los resultados obtenidos al aplicar la metodología de la red neuronal artificial a los diagnósticos de nefritis aguda basados en síntomas seleccionados, muestran las habilidades de la red de aprender patrones correspondientes a los síntomas de la persona. En este estudio, los datos fueron obtenidos del repositorio UCI de aprendizaje automático con el fin de diagnosticar enfermedades. Los datos se separan en entradas y objetivos. Los objetivos de la red neuronal serán identificados con 1's para los infectados y 0's para los no infectados. En el diagnóstico de la enfermedad de nefritis aguda; el porcentaje correctamente clasificado en la muestra de simulación por la red de tipo *Feed-Forward Back Propagation* es de 99 por ciento, mientras que en el diagnóstico de las enfermedades del corazón; el porcentaje correctamente clasificado en la muestra de simulación por la red es 95 por ciento.

1. Introducción

La tarea principal de la ciencia médica radica en prevenir y diagnosticar las enfermedades. En esta monografía haremos foco en la segunda tarea de la medicina, diagnosticar, basándonos en el paper *Importance of Artificial Neural Network in Medical Diagnosis disease like acute nephritis disease and heart disease [1]*, que tiene como objetivo evaluar las redes neuronales artificiales (ANN) en el diagnóstico de enfermedades.

Me llamo la atención este tema ya que la tarea de diagnosticar, a mi entender, no es algo para nada sencilla ni directa. Además, en la actualidad existen diversas dificultades vinculadas con los diagnósticos médicos:

- La calidad del diagnóstico depende totalmente del talento del médico y su experiencia.
- Los problemas emocionales y la fatiga degradan la performance del profesional.
- El procedimiento de formación de los médicos, en particular los especialistas, es largo y costoso. Incluso en los países desarrollados se siente la ausencia de profesionales en el área de la salud.
- La ciencia médica es uno de los campos de la ciencia que más rápidamente crece y cambia. Los nuevos resultados descalifican los anteriores tratamientos, nuevas curas y drogas aparecen cada día. Incluso enfermedades desconocidas aparecen cada tanto. Lo que implica que el médico siempre debe esforzarse por mantenerse al día.

Como estudiante avanzada de la carrera de Ingeniería en Computación, me pregunte como las computadoras podrían ayudar en el diagnóstico médico. Si bien desde hace décadas, las computadoras han sido ampliamente empleadas en el sector médico, para el caso de los diagnósticos médicos, dada la complejidad de la tarea, no es todavía realista esperar un sistema de diagnóstico médico completamente automático basado en computadora. De todas formas, avances recientes en el campo de los sistemas inteligentes van a materializar un uso más amplio de las computadoras, equipadas con técnicas de inteligencia artificial, para esta área.

La ventaja de utilizar sistemas computarizados radica en que las computadoras nunca se cansan o aburren, pueden ser actualizadas fácilmente en cuestión de segundos, y son más baratas y más fáciles de distribuir.

Un buen porcentaje de las personas que asisten a una clínica de salud, no están enfermas o al menos sus problemas no son serios, si un sistema de diagnóstico inteligente puede refinar ese porcentaje, liberará al doctor para que se pueda focalizar en los casos más complejos.

En resumen, ya que en el seminario se dio una conferencia sobre las redes neuronales y su aplicación en los algoritmos de clasificación, sumado al hecho de que las redes neuronales artificiales han sido aplicadas exitosamente a varias áreas de la medicina, tales como: sistemas de diagnóstico, análisis biomédicos, análisis de imágenes, desarrollo de drogas. Me interesó realizar esta monografía basándome en el uso de las redes neuronales artificiales en el área de diagnósticos médicos. Pudiendo comprobar que estas proporcionan una poderosa herramienta para ayudar a los médicos a analizar, modelar y dar sentido a complejos datos clínicos.

2. Desarrollo de la monografía

Como mencionamos anteriormente, el objetivo de esta monografía es evaluar a las redes neuronales artificiales en el diagnóstico de enfermedades. Para esto nos basaremos en el paper *Importance of Artificial Neural Network in Medical Diagnosis disease like acute nephritis disease and heart disease* [1]. En dicho paper dos casos son estudiados. El primer caso es la enfermedad de la nefritis aguda; los datos utilizados son los síntomas de la enfermedad. El segundo caso estudiado, son las enfermedades del corazón, con esta denominación abarcamos las enfermedades de los vasos sanguíneos, tales como enfermedad de la arteria coronaria, problemas del ritmo cardíaco (arritmias) y defectos cardíacos congénitos; los datos son tomados de imágenes SPECT o tomografía computarizada de emisión monofotónica (en inglés *single photon emission computed tomography*) [2].

Modelo de Diagnostico propuesto:

Las redes neuronales de tipo *Feed-Forward* son modelos exitosos y ampliamente utilizados para la clasificación, predicción y solución de problemas. Una típica red neuronal de tipo *Feed-Forward Back Propagation* es el modelo propuesto para diagnosticar las enfermedades. Consiste de tres capas: la capa de entrada, la capa oculta, y la capa de salida. Una capa oculta con 20 neuronas, es creada y entrenada. Las muestras objetivo y de entrada son automáticamente divididas en conjuntos de entrenamiento, validación y prueba. El conjunto de entrenamiento es utilizado para entrenar la red. El entrenamiento prosigue mientras la red continúe mejorando sobre el conjunto de validación. El conjunto de prueba provee una medida completamente independiente de la exactitud de la red. La información se mueve en una sola dirección, hacia adelante, desde los nodos de entrada, a través de los nodos ocultos en dirección hacia los nodos de salida. No existen ciclos ni bucles. Las redes neuronales propuestas se muestran en la figura 1 y 2.

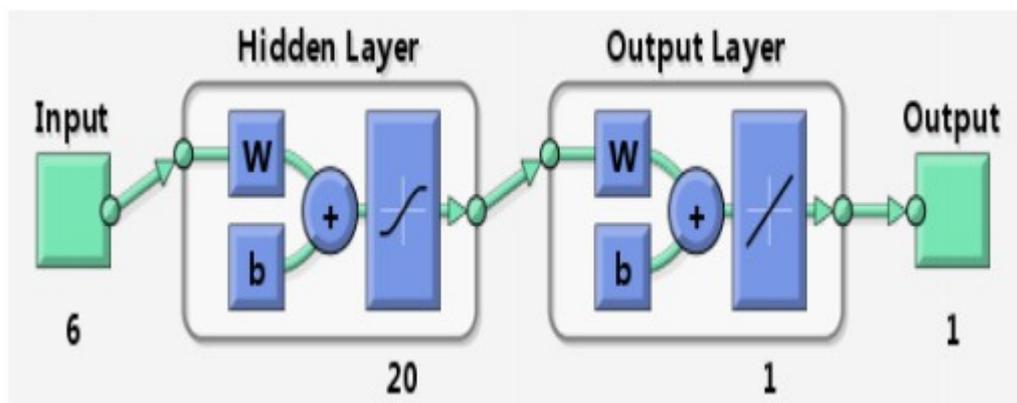


Figura 1. La red neuronal propuesta para diagnosticar la nefritis aguda. Extraído de Irfan Y. Khan, P.H. Zope, S.R. Suralkar, *Importance of Artificial Neural Network in Medical Diagnosis disease like acute nephritis disease and heart disease* [1].

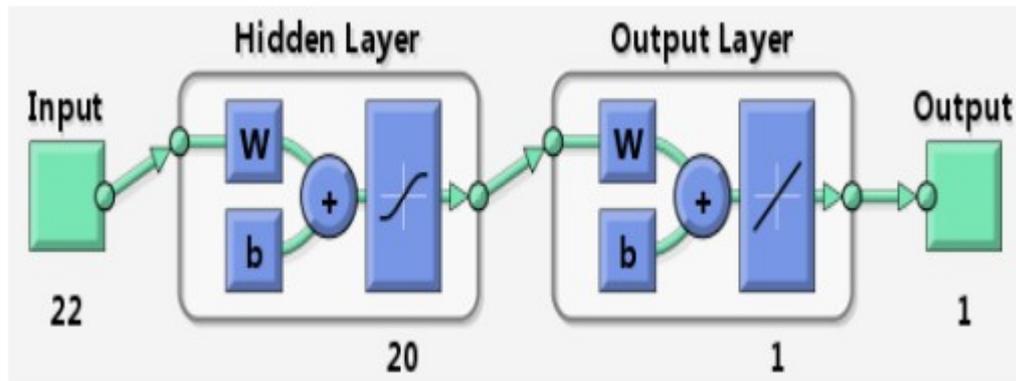


Figura 2. La red neuronal propuesta para diagnosticar las enfermedades del corazón. Extraído de Irfan Y. Khan, P.H. Zope, S.R. Suralkar, *Importance of Artificial Neural Network in Medical Diagnosis disease like acute nephritis disease and heart disease* [1].

Una red neuronal de tipo *Feed-Forward* permite que las señales viajen en una sola dirección; desde el origen hacia el destino; no existe retroalimentación. Las neuronas ocultas son capaces de aprender patrones en los datos durante la etapa de entrenamiento y mapear la relación entre los pares de entrada y salida. Cada neurona en la capa oculta utiliza una función de transferencia para procesar los datos que recibe desde la capa de entrada, y luego transferir la información procesada hacia las neuronas de salida para su posterior procesamiento utilizando una función de transferencia en cada neurona.

La salida de la capa oculta puede ser representada por:

$$Y_{N \times 1} = f(W_{N \times M} X_{M \times 1} + b_{N,1})$$

Donde Y es un vector que contiene la salida de cada una de las N neuronas en una capa dada. W es una matriz que contiene los pesos para cada una de las M entradas para todas las N neuronas, X es un vector que contiene las entradas, b es un vector que contiene los sesgos y $f(.)$ es la función de activación [3].

Resultados Experimentales:

- **Análisis de datos:**

Síntomas, imágenes o señales son los datos utilizados en el diagnóstico médico. El conjunto de datos se obtuvo del *Repositorio de Aprendizaje Automático UCI* [4].

- **Diagnóstico de datos para la nefritis aguda:**

Los datos fueron creados por un médico experto como un conjunto de datos para probar el sistema experto, que llevará a cabo el presunto diagnóstico de una de las enfermedades del sistema urinario.

La idea principal de este conjunto de datos es construir el modelo de la red neuronal, que llevara a cabo el presunto diagnóstico de nefritis aguda. La nefritis aguda de la pelvis renal ocurre considerablemente más frecuentemente en mujeres que en hombres. Comienza con una repentina fiebre, que alcanza, y a veces supera los 40C. La fiebre es acompañada por escalofríos y dolores lumbares, que a veces son muy fuertes.

El conjunto de datos contiene 120 pacientes. La **Tabla 1** muestra los síntomas del paciente que son considerados como variables de diagnóstico. El conjunto de datos contiene 120 muestras. 90 muestras se utilizaron para entrenar la red, mientras que 30 fueron empleadas para probar la red.

Tabla 1. Variable de diagnóstico de los conjuntos de datos utilizados en el estudio.

Síntomas del Paciente	
Nro	Nombre de Variable de Diagnóstico
1	Temperatura del paciente {34C – 42C}
2	Ocurrencia de nauseas {sí, no}
3	Dolor lumbar {sí, no}
4	Necesidad continua de micción {sí, no}
5	Dolores de micción {sí, no}
6	Quemazón en la uretra, picor, hinchazón en la salida de la uretra {sí, no}

Extraído de Irfan Y. Khan, P.H. Zope, S.R. Suralkar, *Importance of Artificial Neural Network in Medical Diagnosis disease like acute nephritis disease and heart disease* [1].

- **Diagnóstico de datos para las enfermedades del corazón:**

El conjunto de datos describe imágenes SPECT o tomografía computarizada de emisión monofotónica (en inglés *single photon emission computed tomography*) [2]. Cada uno de los pacientes es clasificado en dos categorías: normal y anormal. La base de datos de 267 conjuntos de imágenes SPECT (pacientes) fue procesada para extraer las características que resumen las imágenes SPECT originales. Como resultado, 44 patrones de características continuas fueron creados para cada paciente. El patrón fue procesado adicionalmente para obtener 22 patrones característicos binarios. Los datos SPECT tienen 267 instancias que son descritas por 23 atributos binarios. El conjunto de datos contiene 267 muestras. 80 muestras son utilizadas para entrenar la red mientras 187 son empleadas para probar la red.

- **Evaluación de performance:**

Neural network toolbox de Matlab 7.9 es utilizada para evaluar la performance de las redes propuestas. La nefritis aguda de origen pelvis renal es la primera enfermedad a ser diagnosticada. Una red de dos capas de tipo *Feed-Forward* con 6 entradas, 20 neuronas sigmoid ocultas y neuronas de salida lineales, fue creada.

Dicha red puede adaptarse a los problemas de asignación multidimensionales arbitrariamente bien, si cuenta con datos consistentes y suficientes neuronas en su capa oculta, como lo muestra la **Figura 1**.

El algoritmo *back-propagation* utilizado para entrenar la red fue el provisto por Levenberg-Marquardt [5]. El entrenamiento automático se detiene cuando la generalización deja de mejorar, indicado por el incremento en el error cuadrático medio (MSE) ¹de las muestras de validación.

Los resultados obtenidos al aplicar la metodología de las redes neuronales artificiales para distinguir entre una persona saludable y otra no saludable, basados sobre síntomas seleccionados, mostraron muy buenas habilidades de la red para aprender patrones correspondientes a los síntomas de la persona. La red fue simulada en el conjunto de prueba (por ejemplo para casos que la red no había visto antes). Los resultados fueron muy buenos: la red fue capaz de clasificar 99% de los casos en el conjunto de prueba.

La **Figura 3** muestra el estado de la formación de valores. La mejor performance de validación es $2.8548e-007$ en la época 7 como lo muestra la **Figura 4**.

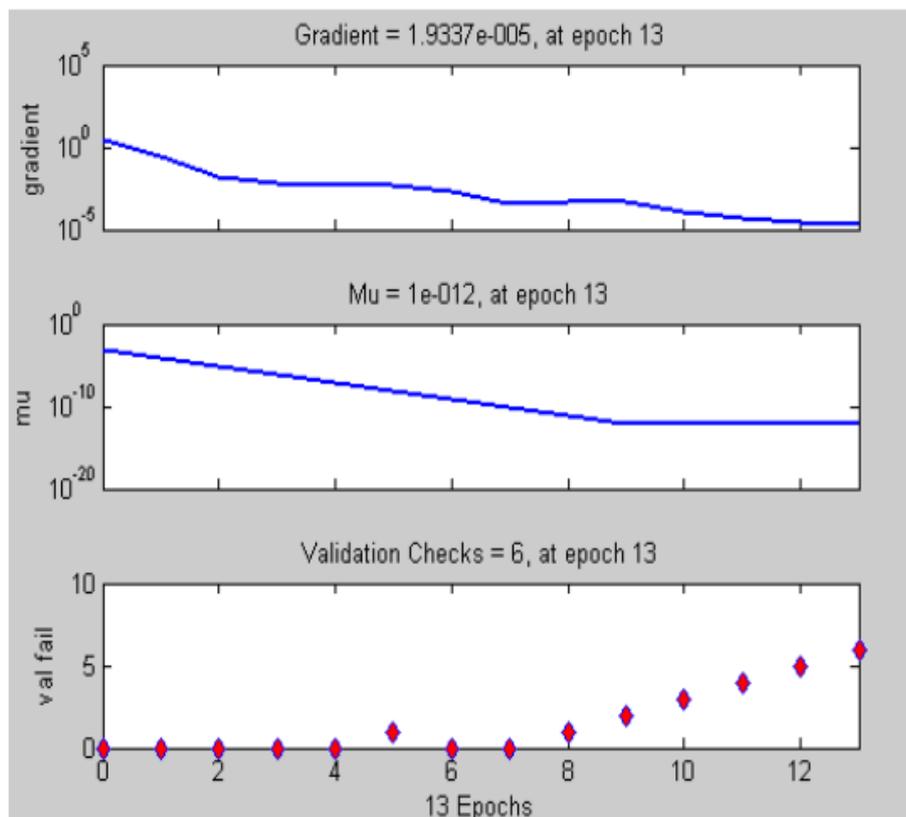


Figura 3. Estado de Formación de Valores. Extraído de Irfan Y. Khan, P.H. Zope, S.R. Suralkar, *Importance of Artificial Neural Network in Medical Diagnosis disease like acute nephritis disease and heart disease* [1].

¹ El error cuadrático medio (MSE) es la diferencia media al cuadrado entre las salidas y los objetivos. Los valores más bajos son mejores, mientras que cero significa que no hay error.

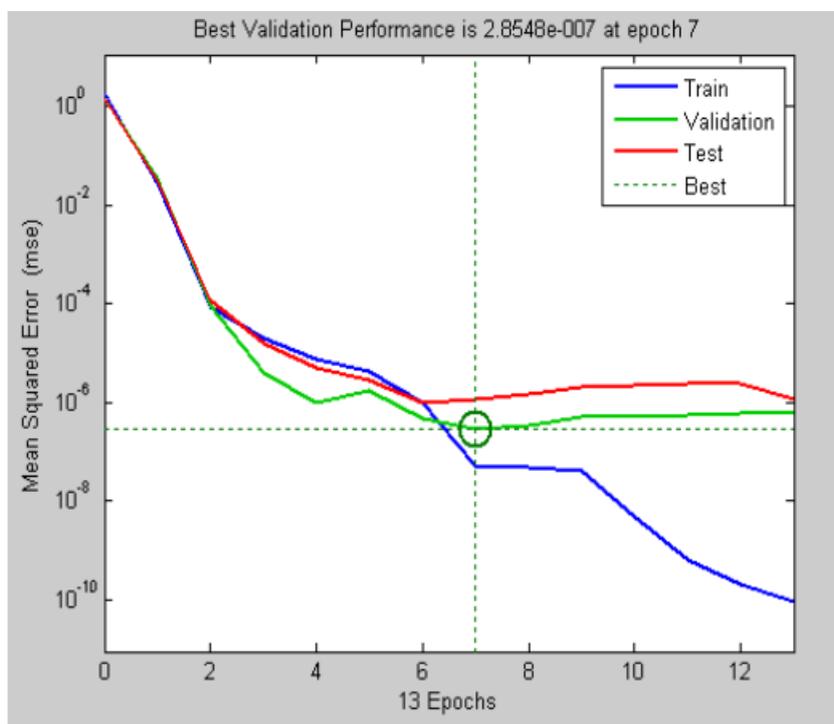


Figura 4. Performance de Validaciones. Extraído de Irfan Y. Khan, P.H. Zope, S.R. Suralkar, *Importance of Artificial Neural Network in Medical Diagnosis disease like acute nephritis disease and heart disease* [1].

Tabla 2. El error cuadrático medio (MSE) y los valores de regresión para los conjuntos de entrenamiento, validación y prueba. Extraído de Irfan Y. Khan, P.H. Zope, S.R. Suralkar, *Importance of Artificial Neural Network in Medical Diagnosis disease like acute nephritis disease and heart disease* [1].

	MSE	R
Training	5.11986e-8	9.99999e-1
Validation	2.85475e-7	9.99999e-1
Testing	1.13132e-6	9.99997e-1

El porcentaje correctamente clasificado en la muestra de simulación por la red de tipo *Feed-Forward Back Propagation* es 99%. El MSE es igual a 3.96199e-5 y la regresión es igual a 9.99936e-1.

Para diagnosticar las enfermedades del corazón, se utilizó una red neuronal artificial de tipo *Feed-Forward* de dos capas, con 22 entradas y 20 neuronas sigmoid ocultas y neuronas de salida lineales.

Dicha red puede adaptarse a los problemas de asignación multidimensionales arbitrariamente bien, si cuenta con datos consistentes y suficientes neuronas en su capa oculta, como lo muestra la Figura 2.

El algoritmo *back-propagation* utilizado para entrenar la red fue el provisto por Levenberg-Marquardt [5]. Los resultados obtenidos al aplicar la metodología de las redes neuronales para distinguir entre una persona normal y anormal, basados sobre patrones de características binarias extraídos de las imágenes SPECT, han mostrado muy buenas habilidades de la red de aprender patrones.

Los resultados fueron muy buenos; la red fue capaz de clasificar 95% de los casos de prueba. La Figura 5, muestra el estado de la formación de valores. La mejor performance de validación es 0.088329 en la época 3 como lo muestra la Figura 6.

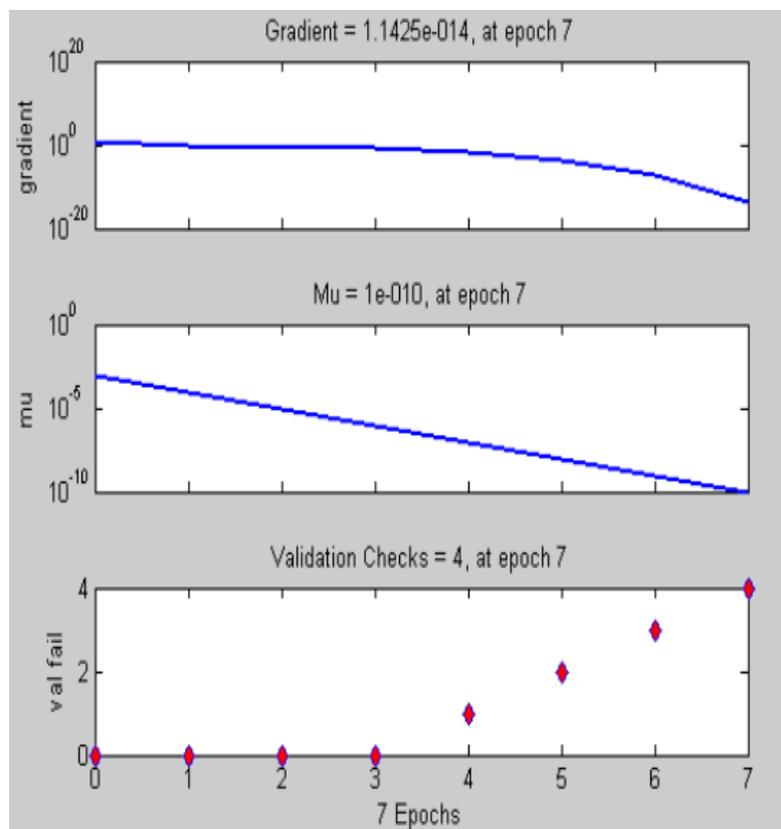


Figura 5. El estado de la formación de valores. Extraído de Irfan Y. Khan, P.H. Zope, S.R. Suralkar, *Importance of Artificial Neural Network in Medical Diagnosis disease like acute nephritis disease and heart disease* [1].

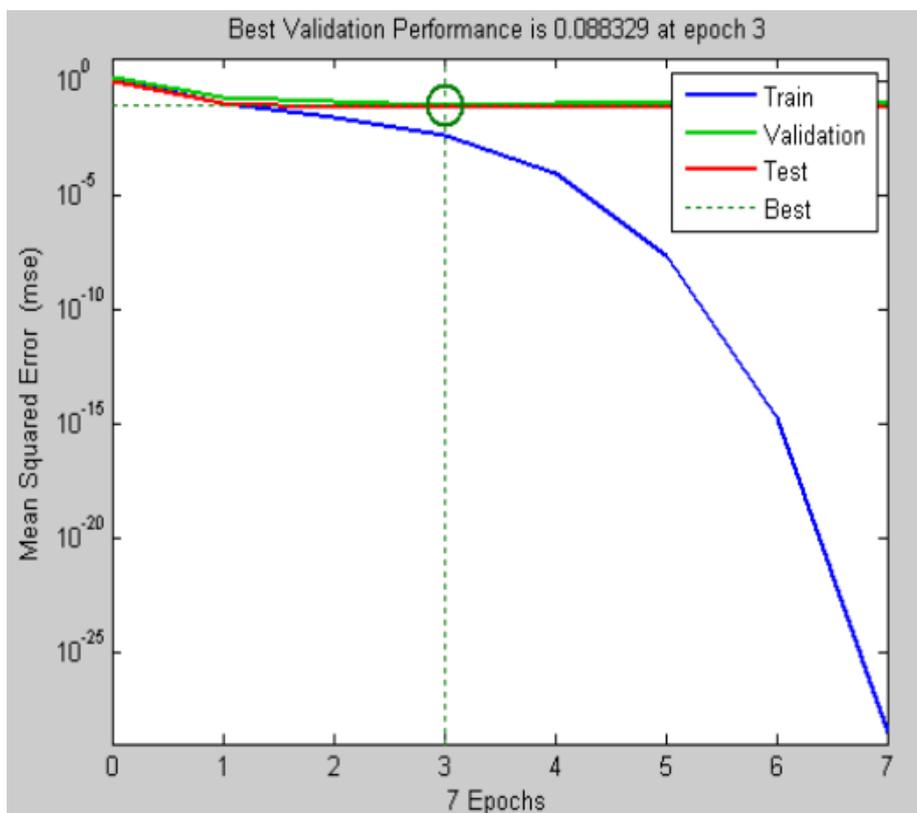


Figura 6. Performance de validación. Extraído de Irfan Y. Khan, P.H. Zope, S.R. Suralkar, *Importance of Artificial Neural Network in Medical Diagnosis disease like acute nephritis disease and heart disease* [1].

Tabla 3. El error cuadrático medio (MSE) y los valores de regresión para los conjuntos de entrenamiento, validación y prueba. Extraído de Irfan Y. Khan, P.H. Zope, S.R. Suralkar, *Importance of Artificial Neural Network in Medical Diagnosis disease like acute nephritis disease and heart disease* [1].

	MSE	R
Training	4.86802e-3	9.92593e-1
Validation	8.83292e-2	8.50794e-1
Testing	7.47611e-2	8.72846e-1

El porcentaje correctamente clasificado en la muestra de simulación por la red de tipo *Feed-Forward Back Propagation* es 95%. El MSE es igual a $2.78711e-2$ y la regresión es igual a $9.50148e-1$.

3. Conclusiones

Este estudio tuvo como objetivo evaluar las redes neuronales en el diagnóstico de enfermedades. La red neuronal de tipo *Feed-Forward Back Propagation* con aprendizaje supervisado es el modelo

propuesto de diagnóstico. Las redes neuronales artificiales mostraron resultados significativos al utilizar datos basados en síntomas e imágenes. Los resultados obtenidos muestran que la red neuronal propuesta puede ser útil para diagnosticar a una persona infectada.

4. Bibliografía

[1] Irfan Y. Khan, P.H. Zope, S.R. Suralkar, *Importance of Artificial Neural Network in Medical Diagnosis disease like acute nephritis disease and heart disease*, International Journal of Engineering Science and Innovative Technology (IJESIT) Volumen 2, Tema 2, Marzo 2013.

[2] *Tomografía computarizada de emisión monofotónica* [online]. Disponible en: http://es.wikipedia.org/wiki/Tomograf%C3%ADa_computarizada_de_emisi%C3%B3n_monofot%C3%B3nica

[3] J. A. Freeman and D. M. Skapura, *Neural networks: algorithms, applications and programming techniques*, Addison Wesley Longman, 1991.

[4] *UCI: Machine Learning Repository* [online]. Disponible en: <http://archive.ics.uci.edu/ml/>

[5] *Levenberg-Marquardt Algorithm* [online]. Disponible en: http://en.wikipedia.org/wiki/Levenberg%E2%80%93Marquardt_algorithm