
Un sistema basado en redes neuronales artificiales para diagnóstico de anemia ferropénica

A system based on artificial neural networks to diagnosis of Anemia iron deficiency

Edinson Muñoz, Jorge Espinoza, Luis Rivera

Universidad Nacional Mayor de San Marcos
Facultad de Ingeniería de Sistemas e Informática

edisonmunoz@gmail.com.

jorluis841@gmail.com.

rivera@uenf.br

RESUMEN

Los médicos confunden el hecho de identificar los tipos de anemias con otras enfermedades, generando casos irreversibles en muchos casos. Frente a esto, se plantea un sistema inteligente basado en Redes Neuronales Artificiales para el Diagnóstico de Anemia Ferropénica y sus similares Megaloblástica y Hemolítica, dado que sus síntomas y factores en la fase inicial son parecidos, de manera que permita auxiliar al profesional de salud a tomar acciones adecuadas. Para ese propósito, se establece una metodología propia con la adecuación de la arquitectura clásica de un sistema experto a una basada en redes neuronales. Como resultado se obtiene un 99% de certeza en los diagnósticos realizados durante la evaluación del sistema.

Palabras clave: red neuronal artificial, anemia ferropénica, sistema inteligente, sistema experto.

ABSTRACT

Doctors mistake in identifying the types of anemias with other diseases, resulting in many cases irreversible cases. Against this, there is an intelligent system based on Artificial Neural Networks for Diagnosis of iron deficiency anemia and megaloblastic and hemolytic similar, since their symptoms and factors in the early stages are similar, allowing the health professional assistant to take appropriate action. For this purpose, a methodology of its own, adapting the classical architecture of an expert system to one based on neural networks. The result is a 99% certainty in diagnoses made during the appraisal.

Keywords: artificial neural network, iron deficiency anemia, smart, expert system.

1. INTRODUCCION

Los diagnósticos de la situación alimentaria y nutricional del Perú, realizada por el Ministerio de Salud – Instituto Nacional de Medicina Tropical, y a través de las Encuestas Demográfica y de Salud Familiar ENDES (2000, 2005 y 2009) [1], demuestran que la anemia, en particular la ferropénica, es alta. Ese comportamiento se observa en la población infantil de las zonas urbano-marginales.

Según Pfreundschuh y Schölmerich [2], existen varios tipos de anemias, como la ferropénica, la megaloblástica, la hemolítica, la anemia por deficiencia de folato, etc., que afectan a la gente de bajos recursos económicos por el bajo nivel de alimentación. Muchas veces, las similitudes de síntomas que generan algunos de esos tipos, o sus mutaciones, inducen a los médicos a diagnosticar el mal en forma errada y a dar tratamientos no adecuados al paciente. Para los pronósticos, por ejemplo, un médico clínico requiere de diferentes exámenes de laboratorios que sólo se concentran en las grandes ciudades, o un médico especializado en esos temas puede diagnosticar con cierto grado de acierto en base a los síntomas y algunos exámenes básicos, pero también ese tipo de especialistas se concentran sólo en las grandes ciudades. Estadísticas demuestran que la desnutrición y el bajo nivel de alimentación es pronunciada en las zonas rurales o marginales, donde ocurren falta de laboratorios y especialistas, por tanto, la detección y el tratamiento oportuno de ese tipo de enfermedad es escasa, lo que es preocupante en muchas regiones de países subdesarrollados.

En este trabajo se plantea una alternativa tecnológica computacional de diagnóstico de la anemia ferropénica, incluyendo las anemias megaloblástica y hemolítica, dado las similitudes de síntomas en fases iniciales de las enfermedades. Esta alternativa tecnológica es un sistema de diagnóstico que sirve de apoyo y consulta al médico, no necesariamente especialista, para obtener un diagnóstico aceptable y oportuno.

El resto del documento está organizado de la siguiente forma: en la Sección 2 se define la anemia Ferropénica y sus variantes desde el punto de vista de su uso para el modelado del sistema inteligente y se muestran los trabajos relacionados, en la Sección 3 se presenta la estructura de sistemas inteligentes y su relación con redes neuronales, en la Sección 4 se formula el modelo

de la red neuronal para la detección de anemias, en la sección 5 se validan los resultados, finalmente, en la Sección 6 se presentan las conclusiones y los futuros trabajos.

2. LA ANEMIA FERROPÉNICA

La anemia es una condición en la cual la sangre carece de suficientes glóbulos rojos, hemoglobina, o es menor en volumen total. Se define como una concentración de hemoglobina inferior al intervalo de confianza del 95% entre individuos saludables y bien nutridos de la misma edad, sexo y tiempo de embarazo [1].

La Anemia Ferropénica se trata de una anemia caracterizada por la disminución o ausencia de los depósitos de hierro, baja concentración de hierro sérico, baja saturación de transferrina y baja concentración de Hemoglobina o del hematocrito [3]. Si bien las causas de anemia son multifactoriales, la deficiencia nutricional debido a una falta de cantidades específicas de hierro en la alimentación diaria se considera el principal factor responsable de su alta prevalencia [4][5].

Las causas multifactoriales de la anemia ferropénica y las consecuencias de ésta se muestran en la Figura 1.

Se observa que la desnutrición ocasiona la deficiencia de hierro, y este a la vez es causa de la anemia ferropénica.

Otras causas son la pérdida de sangre debido a la menstruación en el caso de la mujer y las úlceras gastrointestinales. Los niños menores de 5 años son los más afectados por esa enfermedad, ya que en ese periodo están en la etapa de desarrollo vital que requiere de niveles altos de hierro para su crecimiento, desarrollo psicomotor, inmunidad celular, entre otros. Las mujeres, en especial las gestantes, también son afectadas por este mal, en dicho periodo se pierde hierro por la absorción del niño en el vientre, y esto le genera cansancio, apatía, aumento en el riesgo de prematuridad, entre otros. También afecta en el desarrollo físico y mental del niño.

Estudios médicos especializados en anemias han establecido 27 factores para el diagnóstico adecuado de anemias ferropénica, megaloblástica y hemolítica. Esos factores son informaciones determinantes para este trabajo. En la Tabla 1 se detallan los 27 factores, indicando la presencia o la ausencia de cada factor en los tres tipos de anemias (ver [6] para mayor detalle).

Figura 1. Diagrama detallado de las causas y consecuencias de la Anemia Ferropénica.

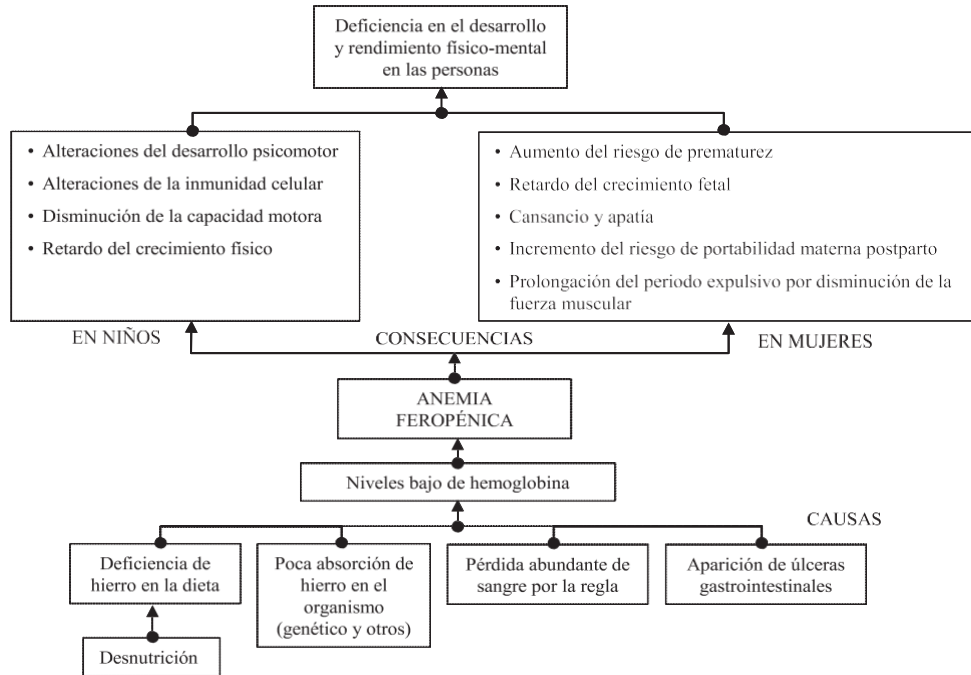


Tabla 1. Factores de la Anemia Ferropénica, Megaloblástica y Hemolítica.

Nº	Factor	Estado		
		Anemia Ferropénica	Anemia Megaloblástica	Anemia Hemolítica
1	Desbalance en dieta alimenticia.	Presente	Presente	Ausente
2	Pica y/o geofagia.	Presente	Ausente	Ausente
3	Embarazos prematuros o múltiples.	Presente	Ausente	Ausente
4	Antecedentes de hiperbilirrubinemia (consecuencia de baja hemoglobina por destrucción de eritrocitos).	Presente	Ausente	Presente
5	Síndrome de malabsorción congénita o hereditaria / Consumo de fármacos (drogas): alteración en absorción de nutrientes.	Presente	Presente	Presente
6	Hemorragias: Menstruación, hemorragias digestivas y/o renales, hemorragia intrauterina, epistaxis (hemorragia de las fosas nasales) / Hemorragias agudas.	Presente	Ausente	Presente
7	Disnea de esfuerzo: dificultad respiratoria al realizar esfuerzos.	Presente	Presente	Ausente
8	Antecedentes de Hipertiroidismo.	Presente	Ausente	Ausente
9	Antecedentes de Gastritis.	Presente	Presente	Presente
10	Esteatorrea: exceso de grasas en las heces.	Presente	Presente	Ausente
11	Anorexia, astenia: debilidad física y psicológica.	Presente	Presente	Presente
12	Alteraciones cardiacas vasculares: taquicardia, soplo sistólico funcional / Descompensación Hemodinámica: mala circulación sanguínea en el sistema cardiovascular.	Presente	Ausente	Presente
13	Carotinemia: Palidez de piel y mucosas (cutanemucosa).	Presente	Presente	Presente
14	Talasemia: enfermedad hereditaria defecto en síntesis de hemoglobina.	Presente	Presente	Presente

15	Litiasis vesicular: concentración de cálculos en la bilis.Colelitiasis: litiasis biliar.	Presente	Ausente	Presente
16	Coloración rosada tenue en la parte blanca de los ojos.	Presente	Ausente	Ausente
17	Esplenomegalia: Dilatación del bazo.	Ausente	Ausente	Presente
18	Manos: Uñas quebradizas.	Presente	Ausente	Ausente
19	Glositis (lengua inflamada) y Estomatitis angular (grietas en la boca).	Presente	Presente	Ausente
20	Edema palpebral (inflamación del ojo), enteropatía exudativa (acumulación de líquido).	Presente	Ausente	Ausente
21	Detención del desarrollo pondoestatural.	Presente	Ausente	Ausente
22	Proceso infeccioso, inflamatorio o tumoral.	Presente	Ausente	Ausente
23	Ictericia: coloración amarillenta de la piel y mucosas.	Ausente	Presente	Presente
24	Vómitos y Diarreas.	Ausente	Presente	Ausente
25	Dolor lumbar (parte maciza de la columna vertebral).	Ausente	Ausente	Presente
26	Orina Oscura.	Ausente	Ausente	Presente
27	Dosaje de Hemoglobina (Hemograma).	Presente	Presente	Presente

3. SISTEMAS INTELIGENTE BASADOS EN REDES NEURONALES

Los sistemas inteligentes son aplicaciones de la Inteligencia Artificial que se comportan con características asociadas a la inteligencia humana. Una de las áreas es el sistema especialista (o sistema experto) que captura en un computador la experiencia de una persona experta en un área determinado del conocimiento, de forma que una persona no experta en el tema pueda aprovechar esa información en la resolución del problema abordado [7]. El sistema especialista, basándose en algunas reglas de acción (silogismos) y el análisis de posibilidades, da una ayuda bastante útil en todas las ramas de la acción humana en ausencia del experto humano. En general, los sistemas especialistas son enfocadas para las tareas de monitorización y diagnóstico. Se complementan con los trabajos de simulación de la realidad, sin embargo, para poder llegar a realizar esas hazañas, los sistemas especialistas pasaron por una evolución desde los primeros modelos basados en reglas de inferencia hasta algunos como los basados en redes neuronales, permitiendo así un mejor desempeño y tiempo de respuesta.

Una red neuronal es un modelo computacional paralelo que hace uso de técnicas de procesamiento paralelo de información, compuesto de unidades procesadoras adaptativas con una alta interconexión entre ellas, haciendo uso de algunos de los principios que organizan la estructura del cerebro humano. Existen diferentes modelos de redes neuronales, pero las que se usan

con frecuencia para el diagnóstico de enfermedades, según Soriano y Blanco [8], es el Perceptrón Multicapa y Red de Kohonen. En este trabajo se optó por el modelo Perceptrón Multicapa, debido a que estudios anteriores demuestran, al menos para situaciones parecidas que se aborda en este trabajo, que es más eficiente que el modelo de Red de Kohonen [9].

Las aplicaciones de las redes neuronales pueden ser divididas según el campo del conocimiento donde se aplican. Dado el contexto de este trabajo, se mencionan las aplicaciones basadas en redes neuronales artificiales en el área médica, que encuentran su reflejo en problemas de diagnóstico. Entre ellas se tienen: utilización del Modelo de Kohonen y del Perceptrón Multicapa para Detectar Arritmias Cardíacas [9], que es un sistema para la detección de arritmias cardíacas mediante redes neuronales adaptativas que reducen el tiempo de análisis y diagnóstico; Sistema Experto de Diagnóstico Médico del Síndrome de Guillian Barre [10]; Sistema Experto para el Diagnóstico de la Epilepsia y Crisis Epilépticas [11]; Entrenamiento Prospectivo y Prueba de una Red Neuronal Artificial como Auxiliar Diagnóstico en el Dolor Abdominal Agudo en un Servicio de Urgencias [12].

Arquitectura del Sistema Inteligente

Una esquematización clásica de Sistema Experto está basada en cuatro procesos genéricos: Adquisición de conocimiento, Representación del conocimiento, Tratamiento del conocimiento, y Utilización del conocimiento.

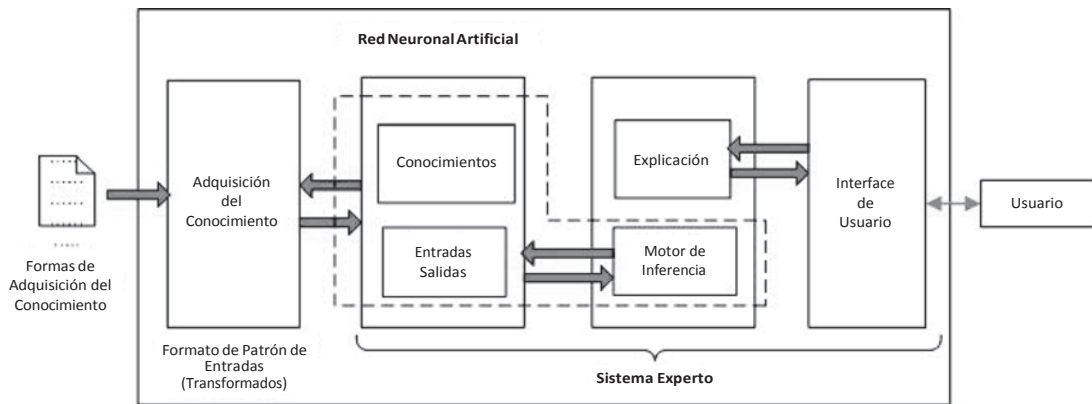
to. Dentro de representación y tratamiento de conocimientos están los módulos clásicos de adquisición del conocimiento, base de conocimientos, base de hechos, motor de inferencia, módulo de explicación e interface de usuario. En este trabajo se propone una arquitectura de un sistema de diagnóstico basada en redes neuronales, tomando como referencia la arquitectura clásica de un sistema experto. La Figura 2 se muestra un esquema de la arquitectura propuesta.

En la arquitectura, los módulos base de conocimiento, base de hechos y el motor de inferencia, se puede substituir por una Red Neuronal Artificial, debido a la similitud de sus funciones. Además, el proceso de Adquisición del Conocimiento vendría a ser parecido al del sistema experto clásico, con la salvedad que aquí se define el formato de los patrones de entrada (mediante

entrevistas u otra forma). La base de conocimiento estaría representada en una red neuronal por los pesos de cada neurona que lo conforma, estos valores se obtienen luego del proceso de aprendizaje. La base de hechos sería el vector de entrada de una red neuronal, esto es temporal al igual que en la arquitectura clásica. Y el motor de inferencia sería al algoritmo el cual se activa para obtener la salida de la red, dentro de éste es donde se encuentra la función de activación de cada neurona. La explicación es parecida al modelo clásico, la cual se encarga de obtener una conclusión y explicación de las salidas.

Por tanto, el modelo se sintetiza en cuatro componentes: adquisición de conocimientos, estructura de la red neuronal, la explicación y la interface de comunicación con el usuario.

Figura 2: Arquitectura del Sistema de Diagnóstico propuesta.



Arquitectura del Sistema Propuesto

En forma general, el sistema inteligente propuesto para la implementación, tal como se ilustra en la Figura 3, se resume a dos componentes: interface de usuario y lógica. El primero es la interface de usuario, que permitirá establecer la comunicación entre el sistema y el usuario, mediante el ingreso de valores de los factores establecidos para el diagnóstico de la enfermedad, el registro de los pacientes y usuarios, la creación de la red neuronal artificial y el entrenamiento de la misma; por tanto, deberá permitir un fácil e intuitivo uso. El segundo componente esencial es la lógica, que es la parte más importante del sistema debido a que éste permite realizar los procesos de acceso y recuperación de información de la base de datos, así como también la construcción de las sentencias de comandos utilizadas para la creación y entrenamiento de la red neuronal

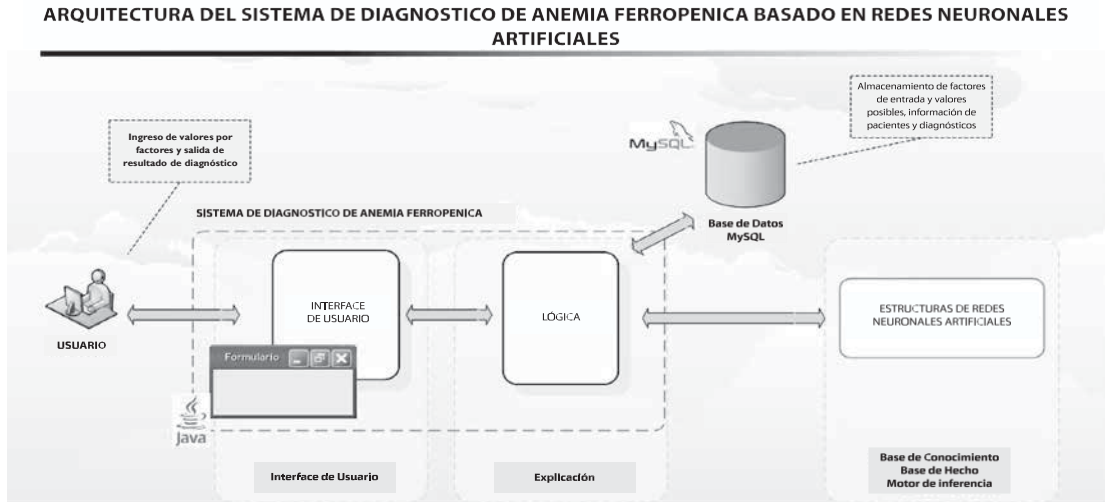
y el diagnóstico, haciendo uso de las redes neuronales entrenadas. De esta manera se obtendrán los valores resultantes del diagnóstico realizado. En el componente lógico se encontraría el modulo de explicación de un sistema experto clásico, con la salvedad que en esta solución es algo más sencillo.

El componente de lógica de la aplicación permitirá la construcción de sentencias de comandos de Matlab, los cuales serán ejecutados por la consola de comandos de esta herramienta mediante la librería JMatLink, la cual se encargará de llamar a la consola para que ejecute dichas sentencias desde la aplicación. La consola de Matlab ejecutará las sentencias construidas por el componente de lógica, tanto para la creación y entrenamiento de las redes neuronales, y el uso de éstas para la realización del diagnóstico. En el caso de la creación de las redes neuronales, Matlab generará

un archivo `_.mat` para cada red; y para el escenario de entrenamiento, hará uso de archivos `_.mat` de entrada y salida para la actualización de los pesos de las redes antes creada. Así mismo, para el diagnóstico, la aplicación empleará los archivos `_.mat` de las redes entrenadas. Cabe mencionar que JMatLink permite la comunicación de una aplicación desarrollada bajo la plataforma Java con la herramienta Matlab.

En estas estructuras de las neuronales artificiales creadas está representada la base de conocimiento, la base de hechos y el motor de inferencia de un sistema experto clásico. La parte de adquisición del conocimiento estaría representada por la fase de definición de factores para el diagnóstico de las anemias, y esto no formaría parte del sistema sino, más bien, de un proceso previo a su desarrollo.

Figura 3. Arquitectura del Sistema de Diagnóstico de la Anemia Ferropénica.



4. MODELO DE LA RED NEURONAL

La topología de las redes neuronales propuestas para la anemia Ferropénica, Megaloblástica y Hemolítica que se tratan en este trabajo, que se muestra en la Figura 4, es del tipo de red Multicapa Unidireccional o Perceptrón Multicapa (MPL), conformada por 4 capas (1 entrada, 2 ocultas y 1 salida), con 27 neuronas de entrada en la primera capa, de acuerdo a las variables de entrada determinadas; con 2 capas ocultas con 40 y 27 neuronas, respectivamente, determinadas por pruebas realizadas en donde se evaluaron la eficiencia de acuerdo a los factores de entrenamiento resultantes, estas capas representan básicamente el nivel de inferencia óptima de la red neuronal para determinar la respuesta; y una neurona en la capa de salida. En esta red se aplicará el algoritmo de aprendizaje Back-propagation, usado generalmente con el modelo MPL. Observe que las 27 neuronas de entrada consideradas en la primera capa equivalen a la entrada de los 27 factores ya analizados para el diagnóstico de las anemias.




Figura 3. Red Neuronal para el Diagnóstico.

Fase de Aprendizaje de las redes neuronales

Para la fase de aprendizaje de las redes neuronales se utilizaron 90 patrones de entrada, 30 para la RNA de la anemia Ferropénica, 30 para la RNA de la anemia Megaloblástica y los otros 30 para la RNA de la anemia Hemolítica, considerándolas en tres formas de ingreso de patrones: ascendente, descendente y aleatorio según su salida esperada, en donde cada patrón es un vector binario de 27 valores correspondientes a todos los factores considerados para las enfermedades tratadas, y para determinar cuál de las tres formas daba un mejor resultado.

Para ello, los datos de entrada serán modelados como una matriz binaria de 27 filas (número de factores) por N columnas, donde N es el número de casos a considerar para el entrenamiento; y contiene los valores de 0 y 1 que representan si presenta (1) o no (0) dicho factor. Además, las salidas esperadas serán representadas en una matriz de 1 fila por N columnas; y que contiene valores en el rango de 0 a 1, que representa la probabilidad de que tenga la enfermedad. La Tabla 2 ilustra el ejemplo de N = 8 patrones, con 27 factores de entrada, y por consiguiente 8 salidas esperadas.

Una vez entrenadas las tres redes neuronales, una por cada tipo de anemia, se obtienen resultados del proceso de aprendizaje. A manera de ejemplo, en la Tabla 3 se muestran los resultados obtenidos con relación a los parámetros de Aprendizaje arrojados para el entrenamiento de la anemia Ferropénica. En la tabla se observan tres líneas de orden (aleatorio, ascendente y descendente respecto al valor de salida Se) en que los 30 patrones fueron ingresados a la red en proceso de aprendizaje. Las columnas son consideradas, según los indicadores que ofrece MatLab para entrenamiento de redes neuronales, en performance o rendimiento de validación, estado de aprendizaje y regresión. El valor de rendimiento indica el porcentaje de error de la red, entonces cuanto menor ese valor es mejor. En este caso, según ese parámetro, el ejemplo indica que el aleatorio es mejor con un valor de 0.0144. En estado de aprendizaje, gradiente es el grado de inclinación de la recta de aprendizaje; esto quiere decir que cuanto mayor valor la convergencia es eminente, en el ejemplo el caso de orden ascendente es mejor. Mu es un parámetro que está relacionado con la variación de valores a lo largo de las iteraciones del proceso de aprendizaje, por tanto cuanto menor es el valor indica tendencia a

Tabla 2. Patrones y Salidas Esperadas para el entrenamiento de una red neuronal artificial.

		PATRONES DE ENTRADA DE TIPO DE ANEMIA							
		PATRONES DE ENTRADA							
		1	2	3	4	5	6	7	8
CÓDIGO FACTORES DE ENTRADA	1	0	1	1	0	1	1	0	0
	2	0	1	1	0	1	1	0	0
	3	0	1	0	0	1	1	0	0
	4	0	0	0	0	0	0	0	0
	5	0	0	0	0	1	0	0	0
	6	0	0	0	0	0	0	0	0
	7	0	0	0	0	0	0	0	0
	8	0	1	1	0	1	1	0	0
	9	0	0	0	0	0	0	0	0
	10	0	0	0	1	0	0	1	1
	11	0	1	1	0	1	1	0	0
	12	0	1	0	0	0	0	0	0
	13	0	0	0	0	0	1	0	0
	14	0	0	0	0	0	0	0	0
	15	0	1	0	0	1	1	0	0
	16	0	1	0	0	1	1	0	0
	17	1	0	0	1	0	0	0	0
	18	0	1	1	0	1	1	0	0
	19	1	0	0	0	0	0	0	1
	20	0	1	1	0	1	1	0	0
	21	0	1	0	0	1	1	0	0
	22	0	1	1	0	1	1	0	0
	23	0	0	0	0	0	0	1	0
	24	0	0	0	1	0	0	0	0
	25	0	0	0	0	0	0	0	0
	26	0	0	0	0	0	0	0	0
	27	0	1	0	0	1	1	0	0
SALIDA (Se)		0.31	0.78	0.66	0.23	0.98	0.87	0.27	0.35

estabilidad; en este caso favoreciendo al proceso de orden aleatorio. En los tres tipos de procesos no existen fallas de validación. El parámetro training indica que casi el 92% de patrones del caso ascendente se alinean a la curva de regresión generada con los datos de entrenamiento. En fin, la media total con el mayor valor

0.694 indica que el proceso aleatorio de aprendizaje es bueno para el caso de anemia Ferropénica. Siguiendo ese proceso, se estableció que las redes para anemias Megaloblástica y Hemolítica, respectivamente, tuvieron mejores comportamientos alimentados con patrones ordenados en forma ascendente.

TABLA 3.
COMPARATIVO DE PARÁMETROS DE LA FASE DE APRENDIZAJE SEGÚN ORDEN DE DE INGRESO DE PATRONES.

		PARÁMETROS DE LA FASE DE APRENDIZAJE DE LA ANEMIA FERROPENICA							
		Performance de Validación	Estado de Aprendizaje			Regresión			
			Gradiente	Mu	Fallos de Validación	Training	Validación	Test	Todo
ORDEN DE APRENDIZAJE	Aleatorio	0.0144	0.129	0.00001	0	0.874	0.684	0.259	0.694
	Ascendente	0.0334	1.07	0.0001	0	0.918	0.244	0.576	0.309
	Descendente	0.0265	0.847	0.0001	0	0.845	0.053	0.481	0.353

5. VALIDACIÓN DEL SISTEMA

Para la validación del sistema fue necesaria la ayuda del médico experto, quien indicó el porcentaje de certeza de 18 casos de pacientes considerado para la evaluación del sistema. Se toma en cuenta la desviación del porcentaje de certeza que da el sistema y el porcentaje de certeza que indicó el médico experto.

Las salidas del sistema obtenidas son plasmadas en la Tabla 4, junto con sus salidas esperadas y el error respectivo. Las abreviaciones AF, AM y AH se refieren a anemia Ferropénica, Megaloblástica y Hemolítica, respectivamente. Las informaciones de los 18 pacientes son representados como P1, P2, ..., P18, cada uno con los 27 atributos binarios que se usó para en el proceso de aprendizaje. Por tanto, los P1, P2, ..., P18 son patrones que la red neuronal acepta como entrada para la clasificación o diagnóstico. En la tabla se observa que P1 es un patrón de anemia Megaloblástica (AM), por tanto se usará la red de Megaloblástica en la validación. Mientras que P18 es un patrón de anemia Ferropénica (AF) que será usado para validar la red de Ferropénica. En resumen, son usados 6 patrones de cada tipo de las tres anemias para validación las respectivas redes neuronales.

Se observa en la tabla que las salidas obtenidas por el sistema varían muy poco respecto a las salidas esperadas por cada caso de un paciente, además, se observa que no se han presentado diagnósticos errados de tipo de anemia que padecía un paciente sino una variación en el porcentaje de certeza. Es por ello que se puede decir que el error más alto obtenido fue de 0.15%. El error promedio obtenido fue de 0.1%, eso indica que los resultados de diagnóstico que se obtienen del sistema presentan una desviación de 0.1%.

De acuerdo a las evaluaciones realizadas (ver en [6]), se ha considerado que con las redes neuronales artificiales se pueden obtener mejores resultados que con otros mecanismos por el tiempo de respuesta obtenido. Ya que normalmente los sistemas inteligentes de diagnóstico médico tardan en hallar la respuesta debido al encadenamiento que realizan, hallando posibles soluciones y tener que compararlas todas, mientras que en este método se ha aplicado valores numéricos o pesos a cada síntoma o factor (determinados durante la fase de aprendizaje), que permite la ejecución de una función de transferencia (mecanismo interno del Matlab) propia de cada neurona, con lo cual se obtiene los resultados de manera más rápida.

Tabla 4.
Resultados del proceso de validación.

Paciente	Salida Esperada	Salida del Sistema	Error
P ₁	86 % - AM	85.85 % - AM	0.15 %
P ₂	87 % - AF	86.91 % - AF	0.09 %
P ₃	89 % - AH	88.88 % - AH	0.12 %
P ₄	89 % - AM	88.95 % - AM	0.05 %
P ₅	89 % - AF	89.19 % - AF	0.19 %
P ₆	92 % - AF	92.11 % - AF	0.11 %
P ₇	93 % - AH	92.93 % - AH	0.07 %
P ₈	93 % - AM	93.04 % - AM	0.04 %
P ₉	94 % - AH	94.15 % - AH	0.15 %
P ₁₀	95 % - AF	94.87 % - AF	0.13 %
P ₁₁	96 % - AH	96.12 % - AH	0.12 %
P ₁₂	97 % - AH	96.87 % - AH	0.13 %
P ₁₃	97 % - AM	97.07 % - AM	0.07 %
P ₁₄	98 % - AM	98.09 % - AM	0.09 %
P ₁₅	98 % - AF	97.90 % - AF	0.10 %
P ₁₆	99 % - AH	99.07 % - AH	0.07 %
P ₁₇	99 % - AM	98.92 % - AM	0.08 %
P ₁₈	99 % - AF	98.91 % - AF	0.09 %
Error Promedio			0.1 %

6. CONCLUSIONES

Se ha propuesto una alternativa tecnológica computacional para el diagnóstico de la anemia ferropénica incluyendo las anemias megaloblástica y hemolítica. La propuesta tecnológica consiste en un sistema basado en redes neuronales artificiales. El modelo de redes neuronales artificiales contempla 27 factores que constituye la capa de entrada, dos capas ocultas con 40 y 27 neurona respectivamente, y una capa de salida que corresponde al diagnóstico. La validación realizada (ver sección 5) muestra que el sistema construido tiene un certeza de 99% en sus resultados, con ello se logra la confianza del usuario necesario para este tipo de sistema.

Como trabajos futuros aún queda poder realizar un sistema de diagnóstico de los diferentes tipos de anemias que existen, poder unificarlos y que trabajen en forma conjunta. Debido a que cada anemia cuenta con diferentes números de características a la hora de tomar un diagnóstico, ello implicaría que diferentes redes trabajen en forma colaborativa.

BIBLIOGRAFÍA

- [1] Instituto Nacional de Estadística e Informática. Perú – Encuesta Demográfica y de Salud Familiar ENDES Continua: 2009, Visión Nacional y Departamental Lima – Perú, 2009.
- [2] Pfreundschuh M; Schölmerich J. Fisiopatología y Bioquímica. Ed. Harcourt S.A., Madrid, 1999.
- [3] Guías Clínicas: Anemia Ferropénica. Atención Primaria en la Red, <http://www.fisterra.com/guias2/aFerropénica.asp#algoritmo>, accesado en Setiembre - 2009.
- [4] Pajuelo, J.; Lizarzaburu, P; Orihuela, P; Acevedo, M. Aportes al estudio del crecimiento de los niños en el Perú. Tesis de Título, Facultad de Farmacia y Bioquímica, UNMSM, Lima - Perú, 1999.
- [5] Instituto Nacional de Estadística e Informática. Perú – Encuesta Demográfica y de Salud Familiar ENDES Continuo: 2001 – 2006, Lima – Perú, 2006.
- [6] Muñoz, Edison y Espinoza, Jorge. Sistema Inteligente Basado en Redes Neuronales Artificiales para Diagnóstico de Anemia Ferropénica. Tesis de Título, Facultad de Ingeniería de Sistemas e Informática, UNMSM, Lima-Perú, 2012.
- [7] Giarratano R.. Sistema Experto Principios y Programación, 3ra. Edición, México, 2001.
- [8] Soria, Emilio; Blanco, Antonio. Redes Neuronales Artificiales. Autores Científico-Técnicos y Académicos, España, 2001.
- [9] Barbosa, L.; Kleisinger, G.; Valdez, A; Monzón, J. Utilización del Modelo de Kohonen y del Perceptrón Multicapa para detectar arritmias cardiacas. Congreso Latinoamericano de Ingeniería Biomédica, 2001, La Habana – Cuba.
- [10] Carlos, M. Sistema Experto para el Diagnóstico Médico del Síndrome de Guillian Barre. Tesis para Título de Licenciado en Computación, Facultad de Ciencias Matemáticas, UNMSM, Lima – Perú, 2002.
- [11] Salcedo G., Pablo E.. Sistema Experto para el Diagnóstico de Enfermedades: Epilepsias y Crisis Epilépticas. Tesis de Título. Facultad de Ingeniería de Sistemas e Informática, UNMSM, Lima – Perú, 2002.
- [12] Cardozo, C. M.; Guadarrama, F.; Reyes, J.; Fernández, R.; Becerra, D. M.; Hernández, M. A.; Lázaro, M.; y Martínez, J. Entrenamiento prospectivo y prueba de una red neuronal artificial diagnóstico en el dolor abdominal agudo en un servicio de urgencias. Revista de la Asociación Mexicana de Medicina Crítica y Terapia Intensiva, Vol. XIV, Nro. 5, 2005, México D.F.

