



## **Diagnóstico de Enfermedades Endémicas con redes neuronales artificiales a través WEKA**

Lourdez Sánchez

Facultad de Ciencias, Tecnologías y Artes  
Universidad Nacional de Pilar  
[lourdezsanchez@gmail.com](mailto:lourdezsanchez@gmail.com)

Gilda Núñez

Facultad de Ciencias Aplicadas  
Universidad Nacional de Pilar  
[gildanunez190@gmail.com](mailto:gildanunez190@gmail.com)

### **RESUMEN**

El Hospital Regional de Pilar registra unas 7000 consultas mensuales en promedio (Bioestadísticas, 2018), de las cuales se necesita clasificar los diagnósticos de enfermedades endémicas. Para ello se utiliza Inteligencia Artificial aplicando la metodología de redes neuronales artificiales que permita realizar la clasificación en base a síntomas principales, a través del entrenamiento de datos en la herramienta WEKA (Waikato Environment for Knowledge Analysis (Weka, s.f.)). Se pudo observar que los modelos resultantes han dado el valor de Kappa 1, en todas las instancias del entrenamiento realizado, lo que denota la modelización perfecta. Se ha propuesto una alternativa tecnológica computacional para la clasificación de las enfermedades endémicas que incluyen Dengue, Influenza y Gastroenteritis. La propuesta tecnológica consiste en un sistema basado en redes neuronales artificiales. El modelo de redes neuronales artificiales contempla 4 síntomas o neuronas para la capa de entrada, 4 capas ocultas con 4 neuronas respectivamente, y 4 capas de salida que corresponde a las enfermedades endémicas. La utilización de redes neuronales artificiales puede ofrecer clasificación de enfermedades endémicas óptimas a los profesionales médicos que realizan consultas en los hospitales públicos. Además podría utilizarse para la clasificación de otros tipos de patologías clínicas.

**Palabras claves:** Inteligencia Artificial – Enfermedades endémicas – Clasificación. Artificial intelligence

## **Diagnosis of Endemic Diseases with artificial neural networks through WEKA**

### **ABSTRACT**

The Regional Hospital of Pilar registers about 7000 monthly consultations on average (Biostatistics, 2018), of which the diagnoses for endemic diseases need to be classified. For this, Artificial Intelligence is used, applying the methodology of artificial neural networks that allows classification based on main symptoms, through data training in the WEKA tool (Waikato Environment for Knowledge Analysis (Weka, s.f.)). It was observed that the consequential models have resulted in the value Kappa 1, in all instances of the training, which indicates a perfect modeling. A computational technological alternative for the classification of endemic diseases including Dengue, Influenza and Gastroenteritis has been proposed. The technological proposal consists of a system based on artificial neural networks. The artificial neural network model includes 4 symptoms or neurons for the input layer, 4 hidden layers with 4 neurons respectively, and 4 output layers corresponding to endemic diseases. The use of artificial neural networks can offer classification of endemic diseases, optimal for medical professionals who perform consultations in public hospitals. It could also be used for the classification of other types of clinical pathologies.

**Keywords:** Artificial Intelligence - Endemic diseases - Classification

Artículo recibido: 09 dic. 2019

Aceptado para publicación: 17 dic. 2019

Correspondencia: [lourdezsanchez@gmail.com](mailto:lourdezsanchez@gmail.com)

Conflictos de Interés: Ninguna que declarar

## **INTRODUCCIÓN**

Una enfermedad endémica es aquella que se presenta constantemente en un área geográfica en un grupo de población; la definición de endemia abarca también la prevalencia usual de una enfermedad en un área o grupo determinado (Torrado, Castañeda, & Fernando de la Hoz, 2000). Las principales enfermedades que se presentan en el Hospital Regional de Pilar son las siguientes: Dengue (Martínez, 2008): una enfermedad febril aguda definida por la presencia de fiebre y dos o más de los siguientes (DGVS-Paraguay, 2015), dolor retro orbital u ocular, dolor de cabeza, erupción cutánea, mialgia, artralgia. También pueden presentarse anorexia, náuseas, dolor abdominal y vómitos persistentes. La influenza (Ballesta, y otros, 2016) (también conocida como la gripe) es una enfermedad respiratoria contagiosa provocada por los virus de la influenza. Las personas con influenza, a veces sienten algunos o estos síntomas: Fiebre\* o sentirse afebrado/con escalofríos, tos, dolor de garganta, dolores musculares y corporales, dolores de cabeza, algunas personas pueden tener vómitos y diarrea, aunque esto es más común en los niños que en los adultos.

El resfriado o catarro común síndrome gripal (Rosas, 2008) es una infección viral aguda del tracto respiratorio que a menudo cursa con inflamación de las vías aéreas altas (nariz, senos paranasales, laringe, tráquea y bronquios) y no produce fiebre. El cuadro se inicia con la aparición de estornudos, rinorrea fluida, acuosa y abundante, picor de garganta, congestión nasal y malestar general. Gastroenteritis: (Alcalde, y otros, 2002) se caracteriza por vómitos y diarrea acuosa durante 3 a 8 días. La fiebre y el dolor abdominal.

Estas enfermedades se encuentran presentes en los síntomas que presentan los pacientes sin embargo, no son clasificadas como endémicas, debido a la cantidad de pacientes que atienden, no poseen una herramienta interactiva que los ayude a dicha clasificación, por lo que se plantea esta propuesta de aplicación de la Inteligencia Artificial con la utilización de Redes Neuronales Artificiales.

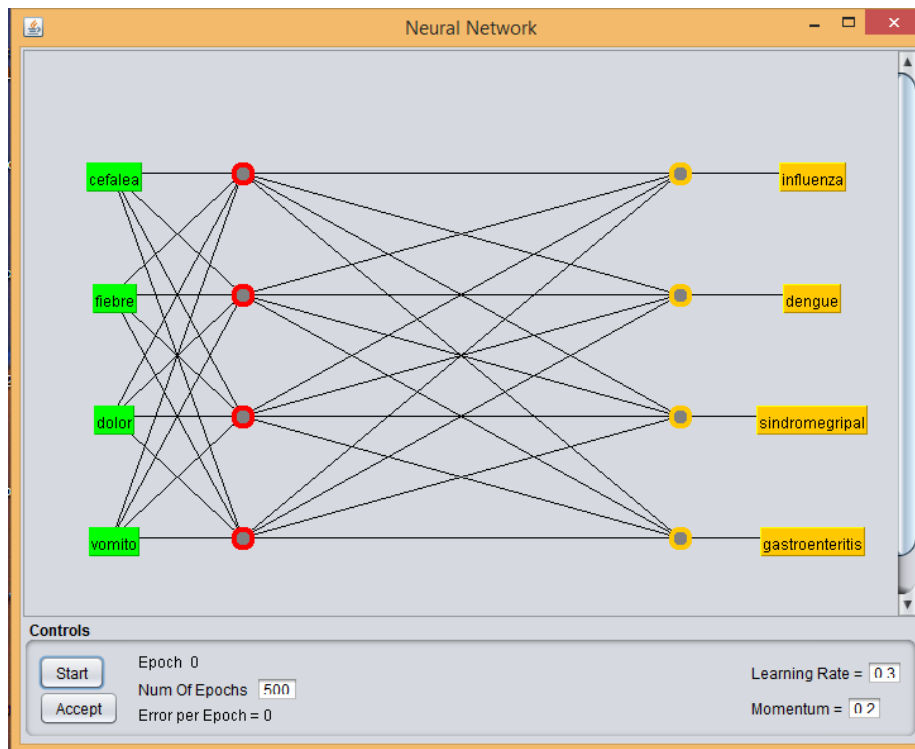
Las Redes Neuronales Artificiales (RNA) Una red neuronal artificial (ANN) (Suman, 2016), a menudo llamada como una "red neuronal" (NN), es un modelo computacional basado en las redes neuronales biológicas, en otras palabras, es una representación y emulación del sistema neuronal humano. Consiste en un grupo interconectado de neuronas artificiales y procesa información utilizando un enfoque conexionista para la computación. En términos prácticos, las redes neuronales son herramientas de modelado de datos estadísticos no lineales (Oladokun, Adbanjo, & Owaba, 2007). Se pueden usar para modelar relaciones complejas entre entradas y salidas o para encontrar patrones en los datos.

Perceptron multicapa (Multi-Layer Perceptron, MLP) (Delsol, Isaia, & Minetti, 2015)

Un MLP es una red feed-forward con aprendizaje supervisado (Hilera & Martínez, 2000; Hertz, Palmer, & Krogh, 1991). El tipo de aprendizaje más utilizado por un perceptrón es el método backpropagation (propagación del error hacia atrás) basado en la generalización de la regla Delta (Hertz, Palmer, & Krogh, 1991). A pesar de sus limitaciones, este método ha contribuido a ampliar de forma considerable el rango de aplicaciones de los MLPs (diagnóstico de enfermedades, clasificación de señales, simulación de la dinámica del brazo de un robot, puntuación para la solicitud de créditos, etc.) En este tipo de aprendizaje, primero se aplica un patrón de entrada como estímulo a la primera capa de las neuronas de la red, el cual se propaga a través de todas las capas ocultas hasta generar una salida (paso forward). Dicha propagación se lleva a cabo al aplicar una función de activación a la suma ponderada, que surge de la combinación lineal de las entradas y las conexiones (o pesos) sinápticos correspondientes. Luego se evalúa el error cometido al comparar el resultado obtenido por las neuronas de salida con el patrón de salida, por medio de una función de costo. A continuación, estos errores se transmiten hacia atrás (paso backward), partiendo de la capa de salida hacia todas las neuronas de la capa intermedia que contribuyan directamente a la salida. Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido un error que describa su aporte relativo al error total. En base a esto, se reajustan los pesos de conexión de cada neurona, de manera que la próxima vez que se presente el mismo patrón, la salida esté más cercana a la deseada. Para acelerar el proceso de aprendizaje se puede añadir un término denominado momento o momentum (Hertz, Palmer, & Krogh, 1991), el cual acelera la convergencia del algoritmo. Otra forma de mejorar el proceso de aprendizaje es adaptar la tasa de aprendizaje,  $\eta$ , durante dicho proceso, conocido como  $\eta$  adaptativo (Hertz, Palmer, & Krogh, 1991), y consiste en modificar el valor de  $\eta$  durante el entrenamiento con el fin de evitar que el error se estanque debido a la presencia de óptimos locales.

La forma más popular de arquitectura de redes neuronales es el perceptrón multicapa (MLP). Un perceptrón multicapa:

- Tiene cualquier cantidad de entradas.
- Tiene una o más capas ocultas con cualquier cantidad de unidades.
- Utiliza generalmente funciones de activación sigmoideas en las capas ocultas.
- Tener conexiones entre la capa de entrada y la primera capa oculta, entre las capas ocultas, y entre la última capa oculta y la capa de salida.



**Figura 1:** Red neuronal de avance. Ambiente WEKA

MLP es especialmente adecuado para aproximar una función de clasificación que establece el ejemplo determinado por los valores del atributo vectorial en una o más clases. MLP entrenado con el algoritmo de propagación de retorno se utiliza para la extracción de datos.

Entre los diferentes métodos, el método más avanzado y preciso es la evaluación mediante el uso de redes neuronales artificiales. MLP.

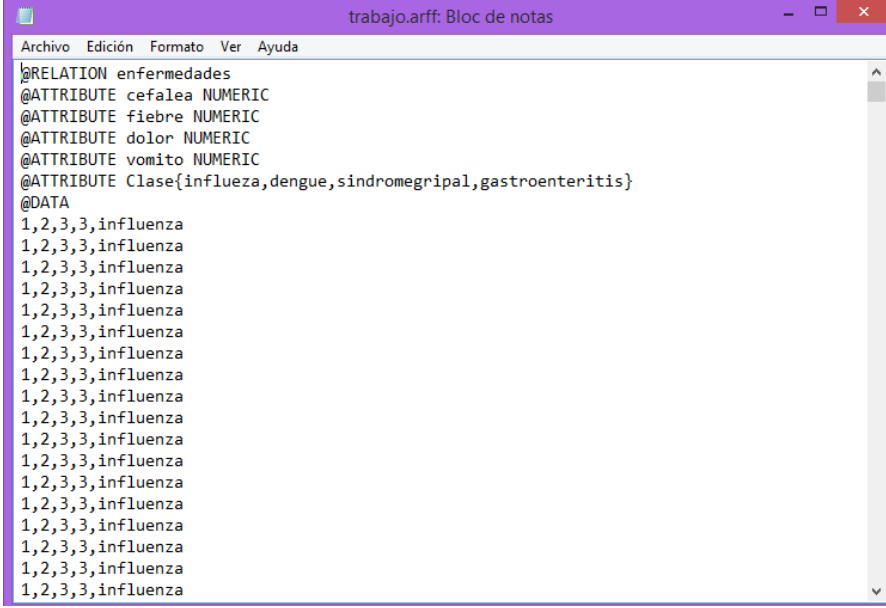
## METODOLOGÍA

El presente trabajo está basado en el entrenamiento de un conjunto de datos, que se obtuvieron del total de consultas de urgencias y ambulatorias llevadas a cabo en el Hospital Regional de Pilar. Se utilizó un conjunto de datos de 800 registros para el entrenamiento y aprendizaje de la red neuronal, los pacientes cuyos síntomas cumplieran con el criterio de enfermedades endémicas de la zona, para poder clasificarlas (Morales, 2014) en Influenza, Dengue, Síndrome gripal y Gastroenteritis. Los atributos seleccionados son el conjunto de síntomas, cefalea, fiebre, dolor, vómito. Para lo cual se establece que:

- El paciente presenta Dengue, si tiene 4 síntomas a la vez (cefalea, fiebre, dolor, vómito).
- El paciente presenta Influenza, si tiene 3 síntomas (cefalea, fiebre, dolor),
- El paciente presenta Síndrome Gripal, si tiene 2 síntomas (cefalea y fiebre),
- El paciente presenta Gastroenteritis, si tiene 3 síntomas (fiebre, dolor, vómito).

Estos atributos fueron ingresados a un formato arff, para la programación del entrenamiento de la Red Neuronal Artificial

**Figura 2:** Archivo arff preparado para el entrenamiento.



```
trabajo.arff: Bloc de notas
Archivo Edición Formato Ver Ayuda
%RELATION enfermedades
%ATTRIBUTE cefalea NUMERIC
%ATTRIBUTE fiebre NUMERIC
%ATTRIBUTE dolor NUMERIC
%ATTRIBUTE vomito NUMERIC
%ATTRIBUTE Clase{influenza,dengue,sindromegripal,gastroenteritis}
%DATA
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
1,2,3,3,influenza
```

La técnica de preprocesamiento de datos se utiliza para identificar datos de ruido, valores de atributo faltantes, datos irrelevantes y redundantes, extraídos del SAA1 con el propósito de identificar el método o técnica de Redes Neuronales Artificiales (RNA) que permita obtener mayores resultados de precisión al identificar estas enfermedades.

Una vez entrenada la RNA, toma los valores siguientes, para la salida de datos, con la siguiente clasificación:

- Dengue: 1cefalea, 2fiebre, 3dolor, 4vómito.
- Influenza: 1cefalea, 2fiebre, 3dolor,
- Síndrome Gripal: 1cefalea, 2fiebre,
- Gastroenteritis: 2fiebre, 3dolor, 4vómito.

En esta investigación, hemos usado WEKA para la implementación de la RNA, usando un aprendizaje supervisado, con un entrenamiento simple y realizando pruebas con la función de perceptrón multicapa MLP. Para esto se utilizó la totalidad de los registros de datos o instancias, que fueron separados en 200 patrones que conducían a la clasificación de las enfermedades, según la cantidad de síntomas presentados, tanto para el entrenamiento como para el aprendizaje. El entrenamiento fue hecho ajustando las diferentes tasas de aprendizaje, impulso y tiempo de

<sup>1</sup> Sistema Área Ambulatoria del Hospital Regional de Pilar  
Ciencia Latina Revista Científica Multidisciplinar, Ciudad de México, México.  
ISSN 2707-2207 / ISSN 2707-2215 (en línea), diciembre, 2019, Volumen 3, Número 1.  
Orcid:/0000-0002-6862-1431 p. 102

entrenamiento. Entre los resultados de la capacitación de la red, fueron seleccionados los mejores tiempos, puesto que el resultado de los modelos han sido perfectos ( $Kappa=1$ )

Ambiente WEKA (Weka, s.f.)

WEKA significa Waikato Environment for Knowledge Aprendizaje. Fue desarrollado por la Universidad de Waikato, Nueva Zelanda. WEKA (Schulz, 2009) admite muchas tareas de minería de datos tales como nuevo procesamiento de datos, clasificación, agrupamiento, regresión y selección de funciones para nombrar algunos atributos. Los formatos de datos admitidos son ARFF (Alegre, 2009), CSV, C4.5 y binarios. Después de cargar los datos, la tarea de preprocesamiento permite agregar, eliminar atributos, la discretización e imputación de los datos (Monsalve Torra, 2017). Weka provee de distintas herramientas de minerías de datos, reglas de asociación, agrupación, clasificación y regresión. Weka es un software de código abierto emitido bajo GNU. Licencia publica general.

### **Entrenamiento de MLP con WEKA**

Se usan los datos para el entrenamiento de la red neuronal con el Clasificador de Weka y su función Multilayer Perceptrón MLP. La Red neuronal artificial es entrenada con un total de 800 instancias de registros de diagnósticos, los síntomas corresponden a las neuronas de entrada que suman 4, así mismo 4 neuronas ocultas y 4 neuronas de salida que corresponde a la clasificación de enfermedades endémicas. Para el aprendizaje se ajusta los parámetros como la tasa de aprendizaje y el impulso hasta obtener un mejor resultado de entrenamiento [learning rate y momentum] del clasificador.

## RESULTADOS

Una vez elegida la función MLP de la herramienta WEKA para la clasificación de los las enfermedades en los registros de pacientes y los parámetros que intervienen, se ha procedido a escoger el método de evaluación del algoritmo para realizar la fase de entrenamiento.

### Se utilizaron 4 atributos y 800 registros

Posteriormente se realiza el análisis de los datos registrados según el método de evaluación escogido y se presentan los siguientes datos: estadísticas Kappa (Ks), error medio absoluto (MAE), raíz del error cuadrático medio (RMSE), error relativo (RAE %), raíz del error cuadrático relativo (RRSE %) en la siguiente Tabla 1, donde se muestran los modelos obtenidos, según la variación de learning rate (taza de aprendizaje), momentum (impulso), N (número de épocas).

Modelo	L	M	N	K	MAE	RMSE	RAE%	RRSE%
1	0.3	0.2	500	1	0.0044	0.0054	1.1761	1.249
2	0.2	0.3	500	1	0.0049	0.006	1.3135	1.3936
3	0.2	0.3	300	1	0.0064	0.0078	1.7084	1.8126
4	0.3	0.2	300	1	0.0057	0.007	1.5241	1.6187

**Tabla 1:** Modelos resultantes del entrenamiento realizado variando el número de épocas

### Validación cruzada: Cross-Validation

La validación cruzada, una técnica de evaluación estándar, es una forma sistemática de ejecutar splits porcentuales repetidos (Weka, s.f.). Divide un conjunto de datos en 10 partes ("pliegues"), luego sostiene cada pieza para analizar y entrena los 9 restantes juntos. Esto proporciona 10 resultados de evaluación, que se promedian. En la validación cruzada "estratificada", al realizar una división inicial nos aseguramos de que cada pliegue contenga aproximadamente la proporción correcta de los valores de clase. Después de realizar una validación cruzada de 10 veces y calcular los resultados de la evaluación, Weka invoca el algoritmo de aprendizaje a una última (11ma) vez en todo el conjunto de datos para obtener el modelo que imprime.

Se aplica la validación cruzada estratificada del número de particiones dado (Folds), de la siguiente manera: El conjunto de datos de entrenamiento se particiona aleatoriamente en dos subconjuntos disjuntos: Subconjunto de estimación, para seleccionar el modelo y Subconjunto de validación, para evaluar o validar el modelo. Es decir se divide los datos en n partes, y por cada parte se construye el clasificador con la n-1 partes restantes, y se prueba con esa, conservando las propiedades de la muestra original (porcentaje de elementos de cada clase).



Cuyos testeos arrojaron los siguientes datos.

1. Para Cross-validation: Folds =10

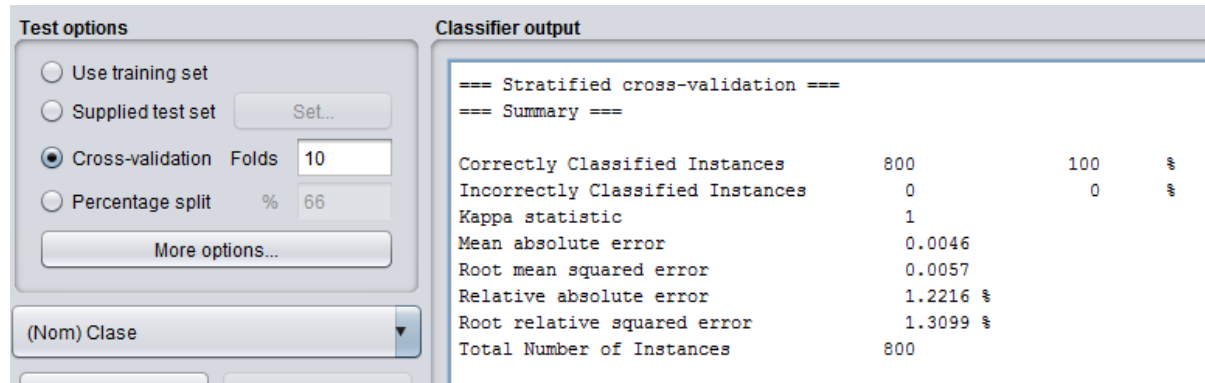


Figura 3: Resultados de Cross- validación folds 10.

2. Para Cross-validation: Folds =20

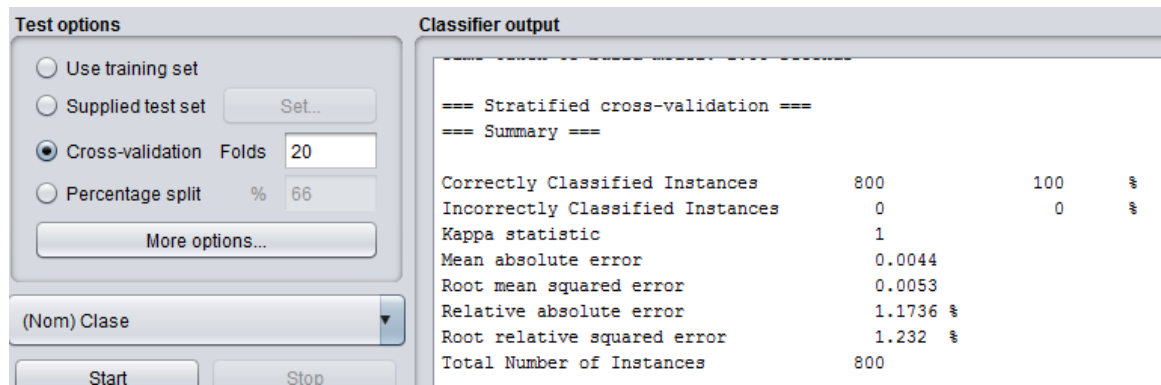
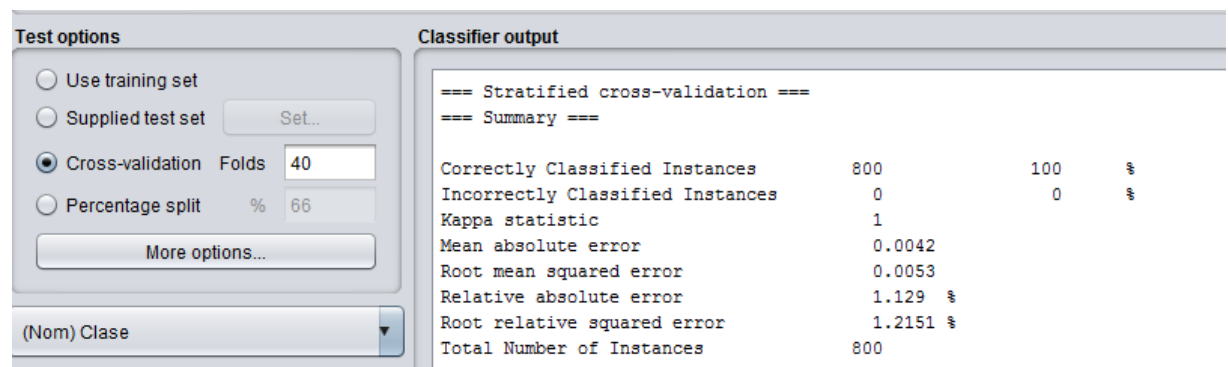


Figura 4: Resultados de Cross- validación folds 20.

3. Para Cross-validation: Folds =40



**Resultados de Cross- validación folds 40.**

**Percentage split:** se evalúa la calidad del clasificador según lo bien que clasifique un porcentaje de los datos reservados para test.

**Classifier output**

```

=== Summary ===
Correctly Classified Instances      720      100 %
Incorrectly Classified Instances    0         0 %
Kappa statistic                    1
Mean absolute error                 0.0152
Root mean squared error             0.0187
Relative absolute error             4.0435 %
Root relative squared error         4.3185 %
Total Number of Instances          720

=== Detailed Accuracy By Class ===
              TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
1,000  0,000  1,000  1,000  1,000  1,000  1,000  1,000  influenza
1,000  0,000  1,000  1,000  1,000  1,000  1,000  1,000  dengue
1,000  0,000  1,000  1,000  1,000  1,000  1,000  1,000  sindromegripal
1,000  0,000  1,000  1,000  1,000  1,000  1,000  1,000  gastroenteritis
Weighted Avg.  1,000  0,000  1,000  1,000  1,000  1,000  1,000  1,000

=== Confusion Matrix ===
  a  b  c  d  <-- classified as
178  0  0  0 | a = influenza
  0 181  0  0 | b = dengue
  0  0 182  0 | c = sindromegripal
  0  0  0 179 | d = gastroenteritis
    
```

**Resultados de Percentage split 10%**

**Classifier output**

```

=== Summary ===
Correctly Classified Instances      272      100 %
Incorrectly Classified Instances    0         0 %
Kappa statistic                    1
Mean absolute error                 0.0053
Root mean squared error             0.0064
Relative absolute error             1.3999 %
Root relative squared error         1.4669 %
Total Number of Instances          272

=== Detailed Accuracy By Class ===
              TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Class
1,000  0,000  1,000  1,000  1,000  1,000  1,000  1,000  influenza
1,000  0,000  1,000  1,000  1,000  1,000  1,000  1,000  dengue
1,000  0,000  1,000  1,000  1,000  1,000  1,000  1,000  sindromegripal
1,000  0,000  1,000  1,000  1,000  1,000  1,000  1,000  gastroenteritis
Weighted Avg.  1,000  0,000  1,000  1,000  1,000  1,000  1,000  1,000

=== Confusion Matrix ===
  a  b  c  d  <-- classified as
 63  0  0  0 | a = influenza
  0  79  0  0 | b = dengue
  0  0  68  0 | c = sindromegripal
  0  0  0  62 | d = gastroenteritis
    
```

### Resultados de Percentage split 66%

**Classifier**  
 Choose: **MultilayerPerceptron -L 0.3 -M 0.2 -N 500 -V 0 -S 0 -E 20 -H a**

**Test options**  
 Use training set  
 Supplied test set  
 Cross-validation Folds: 40  
 Percentage split %: 66  
 More options...

**Classifier output**

```

=== Summary ===
Correctly Classified Instances      112      100 %
Incorrectly Classified Instances    0         0 %
Kappa statistic                    1
Mean absolute error                 0.0044
Root mean squared error             0.0055
Relative absolute error             1.1593 %
Root relative squared error        1.2603 %
Total Number of Instances          112

=== Detailed Accuracy By Class ===
          TP Rate  FP Rate  Precision  Recall  F-Measure  MCC   ROC Area  PRC Area  Class
1,000   0,000   1,000     1,000   1,000     1,000  1,000   1,000   influenza
1,000   0,000   1,000     1,000   1,000     1,000  1,000   1,000   dengue
1,000   0,000   1,000     1,000   1,000     1,000  1,000   1,000   sindrome gripal
1,000   0,000   1,000     1,000   1,000     1,000  1,000   1,000   gastroenteritis
Weighted Avg.  1,000   0,000   1,000     1,000   1,000     1,000  1,000   1,000

=== Confusion Matrix ===
 a  b  c  d  <-- classified as
24  0  0  0 | a = influenza
 0 42  0  0 | b = dengue
 0  0 26  0 | c = sindrome gripal
 0  0  0 20 | d = gastroenteritis
  
```

**Result list (right-click for options)**

- 17:00:39 - functions.MultilayerPerceptron
- 17:21:22 - functions.MultilayerPerceptron
- 17:52:20 - functions.MultilayerPerceptron
- 17:56:23 - functions.MultilayerPerceptron
- 17:58:59 - functions.MultilayerPerceptron
- 18:12:01 - functions.MultilayerPerceptron
- 18:13:05 - functions.MultilayerPerceptron

### Resultados de Percentage split 86%

Modelo	L	M	N	K	MAE	RMSE	RAE%	RRSE%
1	0.3	0.2	500	1	0.0044	0.0054	1.1761	1.249
Cross_valitation	Folds =10				0.0046	0.0057	1.2216	1.3099
	Folds = 20				0.0044	0.0053	1.1736	1.232
	Folds = 40				0.0042	0.0053	1.129	1.2151
Percentage split	10%				0.0152	0.187	4.0435	4.3185
	66%				0.0053	0.0064	1.3999	1.4669
	86%				0.0044	0.0055	1.1593	1.2603

**Tabla 2:** Resultados de validaciones realizadas

Se ha realizado testeos al Modelo 1 utilizando las opciones Cross-validation y Percentage Split: como se observa en la Tabla 2, y se puede mencionar que los valores resaltados de ambas opciones se acercan a los valores MAE, RMSE, RAE%, RRSE% del modelo mencionado.

## **Discusión**

Como puede visualizarse estos modelos resultantes han dado el valor de Kappa 1, en todas las instancias del entrenamiento realizado, lo que denota la modelización perfecta.

Sin embargo existe variación mínima en los resultados, cuando el aprendizaje es mayor y el impulso es menor, en contra partida cuando el aprendizaje es menor y el impulso es mayor, siendo igual la época, es decir 500.

### **El error medio absoluto (MAE)= 0.0044 y 0.0049**

- La raíz del error medio cuadrático (RMSE)= 0.0054 y 0.006
- El error relativo (RAE)= 1.1761 % y 1.3135 %
- La raíz del error cuadrático relativo (RRSE), 1.249 % y 1.3936 %.

### **Variamos la época a 300, y se visualiza una diferencia en los resultados:**

- El error medio absoluto (MAE)= 0.0064 y 0.0057
- La raíz del error medio cuadrático (RMSE)= 0.0078 y 0.007
- El error relativo (RAE)= 1.7084 % y 1.5241 %
- La raíz del error cuadrático relativo (RRSE), 1.8126 % y 1.6187 %.

Cuando disminuimos la época o tiempo de entrenamiento podemos afirmar que la red aprende muy rápido, arrojando diferentes resultados.

Una vez realizado testeos al Modelo 1 y utilizando las opciones Cross-validation y Percentage Split: como se observa en la Tabla 2, se puede mencionar a partir de los resultados de Cross-validation que independientemente de los datos particionados el modelo tiene una precisión en su comportamiento.

Así mismo según los resultados obtenidos por la opción de testeo Percentage Split (porcentaje de división), podemos mencionar que la calidad de clasificación, se comporta de igual manera con la mayoría de los datos entrenados, sin importar la división de los datos.

## **CONCLUSIONES**

Se ha propuesto una alternativa tecnológica computacional para la clasificación de las enfermedades endémicas que incluyen Dengue, Influenza, Síndrome Gripal y Gastroenteritis. La propuesta tecnológica consiste en un sistema basado en redes neuronales artificiales. El modelo de redes neuronales artificiales contempla 4 síntomas o neuronas para la capa de entrada, 4 capas ocultas con 4 neuronas respectivamente, y 4 capas de salida que corresponde a las enfermedades endémicas. La utilización de redes neuronales artificiales puede ofrecer clasificación de enfermedades endémicas óptimas a los profesionales médicos que realizan consultas en los hospitales públicos. Además podría utilizarse para la clasificación de otros tipos de patologías clínicas y sobre todo para la toma de decisiones a nivel gerencial- directivo, y epidemiológico.

Sin importar los valores de los datos ingresados a la red y los distintos experimentos, se puede concluir que la tendencia es la misma gracias al alto nivel de efectividad del resultado del procesamiento de los datos, a decir por los testeos realizados.

**REFERENCIAS**

- Alcalde, C., Gómez, L., Carrascal, M., Blanco del Val, A. M., Bedate, P., González, A., & Jiménez, E. (2002). Gastroenteritis aguda en pacientes hospitalizados. Estudio evolutivo de 14 años. *Science Direct*, 56, 104-110. doi:[https://doi.org/10.1016/S1695-4033\(02\)78939-X](https://doi.org/10.1016/S1695-4033(02)78939-X)
- Alegre, A. (2009). Simulación de redes neuronales artificiales. *Informática: Sistemas operativos y Simulación RNA*. Corrientes.
- Ballesta, J., Vigil, M., González, M., Solana, M., Ruíz, E., González, L., Monteagudo, L. (26 de octubre de 2016). No sólo un síndrome gripal. *Semergen Elsevier*, 42-65.
- Bioestadísticas. (2018). Informe mensual de Control de Gestión. Pilar: HRP - MSPBS.
- McCulloch, W.S. and Pitts, W. (1973) A logical calculus of the ideas immanent in nervous activity, *Bulletin of Mathematical Biophysics* 1973;5,115-137.
- Delsol, K., Isaia, M., & Minetti, G. (2015). Aplicación de algoritmos aproximados al diagnóstico/clasificación de enfermedades. 16° Simposio Argentino de Inteligencia Artificial (págs. 49-56). La Pampa: Universidad Nacional de La Pampa. Obtenido de <http://44jaiio.sadio.org.ar/sites/default/files/asai49-56.pdf>
- DGVS-Paraguay. (2015). Plan para Mejorar la Vigilancia del Síndrome Febril en la Red de Servicios de Salud de Paraguay. Asunción: MSPBS.
- Hertz, J., Palmer, R., & Krogh, A. (1991). *Introduction to the Theory of Neural Computation*. Perseus Publishing.
- Hilera, J., & Martínez, V. (2000). *Redes Neuronales Artificiales*. México DF: Alfaomega-Rama.
- Martínez, E. (2008). Dengue. *scielo*, 22(64). doi:<http://dx.doi.org/10.1590/S0103-40142008000300004>
- Monsalve Torra, A. E. (2017). *Sistemas de Ayuda a la Decisión Clínica en Enfermedades de Diagnóstico Computacional*. Alicante: El Taller Digital.
- Morales, A. (2014). Algoritmos Genéticos con medidas de diversidad para el diagnóstico del riesgo de HTA en escolares. Las Villas: Universidad Central "Marta Abreu".
- Oladokun, V., Adbanjo, A., & Owaba, C. (2007). Predicting Students' Academic Performance using Artificial Neural Network: A case study of an Engineering course\*. *Elsevier*(2).
- Rosas, M. (2008). *Educación Sanitaria: Gripe y resfriado*. 27(2), 46-51.

- Rosenblatt, F.(1958), The perceptrón: a probabilistic model for information storage and organization in the brain, *Psychological Review*; 64, 386-408.
- Schulz, G. (2009). Un ambiente integrado de Clasificación, Selección y Ponderación de Reglas basado en Sistemas Inteligentes. Buenos Aires: Universidad de Buenos Aires.
- Suman, S. (2016). Perfomance Evaluation By Artificial Neural Network Using WEKA. *Internacional Research Journal of Engineering and Technology (IRJET)*, 3(56), 03-16. doi:2395/0056
- Torrado, E., Castañeda, E., & Fernando de la Hoz, A. (2000). Paracoccidioidomicosis: definición de las áreas endémicas de Colombia. *Biomédica*, 20(4), 327-334. doi:<https://doi.org/10.7705/biomedica.v20i4.1076>
- Weka. (s.f.). Weka. (The University of Waikato) Recuperado el 20 de 07 de 2018, de <http://www.cs.wailato.ac.nz/ml/weka/> Universidad de Waikato, Nueva Zelanda. CC Creative Commons Attribution 4.0 International License.