



Ciencia Latina
Internacional

Ciencia Latina Revista Científica Multidisciplinar, Ciudad de México, México.
ISSN 2707-2207 / ISSN 2707-2215 (en línea), noviembre-diciembre 2024,
Volumen 8, Número 6.

https://doi.org/10.37811/cl_rcm.v8i6

**SIMEÓN: RED NEURONAL ARTIFICIAL
PARA ANALIZAR EL AUSENTISMO LABORAL
DE LOS TRABAJADORES DE UN
SISTEMA EDUCATIVO ESTATAL**

**SIMEON: ARTIFICIAL NEURAL NETWORK TO
ANALYZE WORKPLACE ABSENTEEISM OF WORKERS
IN A STATE EDUCATIONAL SYSTEM**

Netzahualcóyotl Saucedo Martínez

Instituto Superior de Educación Normal del Estado de Colima

Jorge Alejandro Chávez Larios

Tecnológico Nacional de México

Esteban Núñez Sánchez

Instituto Superior de Educación Normal del Estado de Colima

Hugo Gerardo Castrejón Cerro

Tecnológico Nacional de México

Acacia Pérez Barragán

Instituto Superior de Educación Normal del Estado de Colima

DOI: https://doi.org/10.37811/cl_rcm.v8i6.15232

Simeón: Red Neuronal Artificial para Analizar el Ausentismo Laboral de los Trabajadores de un Sistema Educativo Estatal

Netzahualcóyotl Saucedo Martínez¹

netza.saucedo.rh@isencolima.edu.mx

<https://orcid.org/0000-0003-0810-3883>

Instituto Superior de Educación Normal
del Estado de Colima

Profr. Gregorio Torres Quintero

Jorge Alejandro Chávez Larios

jorge.chavez@colima.tecnm.mx

<https://orcid.org/0000-0003-3038-7739>

Tecnológico Nacional de México

Campus Colima

Esteban Núñez Sánchez

esteban.nunez.ti@isencolima.edu.mx

<https://orcid.org/0000-0001-5862-8309>

Instituto Superior de Educación Normal
del Estado de Colima

Profr. Gregorio Torres Quintero

Hugo Gerardo Castrejón Cerro

hcastrejon@colima.tecnm.mx

<https://orcid.org/0009-0006-2061-1679>

Tecnológico Nacional de México

Campus Colima

Acacia Pérez Barragán

perez.acacia@isencolima.edu.mx

<https://orcid.org/0009-0001-1791-6272>

Instituto Superior de Educación Normal
del Estado de Colima

Profr. Gregorio Torres Quintero

RESUMEN

Este estudio se enfocó en diseñar una Red Neuronal Artificial (RNA) que permita establecer una metodología para el cálculo del presupuesto que por el pago de suplencias eroga año con año el Gobierno de un estado de la República Mexicana, esta investigación se enmarcó en Línea de Generación y Aplicación del Conocimiento (LGAC) denominada Gestión Educativa del Instituto Superior de Educación Normal del Estado de Colima “Profr. Gregorio Torres Quintero” ya que se busca publicar estudios sobre los procesos de la vida cotidiana en las escuelas y los sistemas y políticas educativas, para identificar rasgos, características y aspectos que obstaculizan o favorecen mejores resultados, de igual manera, se trabajó de manera colaborativa con docentes del Tecnológico Nacional de México quienes coadyuvaron en el análisis de la información para el diseño de la red. Los objetivos planteados fueron que la RNA pueda determinar con un 95% de efectividad el nivel educativo en dónde se requiere de mayor presupuesto para el pago de suplencias y establecer la correlación entre el ausentismo laboral y el nivel de logro académico de los alumnos pertenecientes a las escuelas de educación básica del sistema educativo estatal. Lo anterior aprovechando la información recabada a lo largo de 19 años por un módulo de electrónico mediante el cual se capturan las incidencias del personal, para determinar el tamaño de la muestra se decidió que solo aquellos registros en los cuales la escuela perteneciera al nivel de educación básica (Preescolar, Primaria y Secundaria) serían tomados en cuenta, de igual manera, se dejaron de lado aquellas incidencias que no son susceptibles de sustituir ya sea debido a cuestiones normativas o aquellas que no representan un gasto extra en el presupuesto. Entre los resultados más sobresalientes fueron las ventajas que presentan las redes neuronales artificiales con las estadísticas destacan el excelente rendimiento que presentan las primeras ante problemas no lineales o información con mucho ruido y que Simeón puede inferir, con base en la información proporcionada, cuáles serán las enfermedades que más se presenten a lo largo del ejercicio fiscal y quiénes son los más susceptibles a presentarlas.

Palabras clave inteligencia artificial, I + D, presupuesto del estado

¹ Autor principal

Correspondencia: netza.saucedo.rh@isencolima.edu.mx

Simeon: Artificial Neural Network to Analyze Workplace Absenteeism of Workers in a State Educational System

ABSTRACT

This study focused on designing an Artificial Neural Network (ANN) that allows establishing a methodology for calculating the budget that the Government of a state of the Mexican Republic spends year after year for the payment of substitutes, this research was framed in Line of Generation and Application of Knowledge (LGAC) called Educational Management of the Higher Institute of Normal Education of the State of Colima “Profr. Gregorio Torres Quintero” since it seeks to publish studies on the processes of daily life in schools and educational systems and policies, to identify features, characteristics and aspects that hinder or favor better results, in the same way, we worked collaboratively with teachers from the National Technology of Mexico who helped in the analysis of the information for the design of the network. The objectives set were that the RNA could determine with 95% effectiveness the educational level where a greater budget is required for the payment of substitutes and establish the correlation between work absenteeism and the level of academic achievement of the students belonging to the basic education schools of the state educational system. The above, taking advantage of the information collected over 19 years by an electronic module through which staff incidents are captured, to determine the sample size it was decided that only those records in which the school belonged to the education level basic (Preschool, Primary and Secondary) would be taken into account, in the same way, those incidents that cannot be replaced were left aside either due to regulatory issues or those that do not represent an extra expense in the budget. Among the most outstanding results were the advantages that artificial neural networks present with statistics, highlighting the excellent performance that the former present when faced with non-linear problems or information with a lot of noise and that Simeon can infer, based on the information provided, what the diseases that occur most throughout the fiscal year and who is most susceptible to presenting them.

Keywords artificial intelligence, R&D, state Budget

Artículo recibido 02 octubre 2024

Aceptado para publicación: 10 noviembre 2024



INTRODUCCIÓN

Simeón: Red Neuronal Artificial para Analizar el Ausentismo Laboral de los Trabajadores de un Sistema Educativo Estatal tiene como objetivo diseñar una red neuronal que permita analizar el ausentismo laboral de los trabajadores dependientes del sistema educativo estatal, las sustituciones que por licencia médica se extiendan y que eficiente la programación del presupuesto para el pago de suplencias, para una mejor comprensión del documento, este se divide en cuatro apartados, la introducción, hace una reseña del sistema educativo estatal, es decir, cuántos centros escolares dependen de ella, el número de personal docente, de apoyo y asistencia a la educación que allí labora y la cantidad de alumnos que atiende, de igual manera, establece los objetivos que marcan la línea de la investigación. En el segundo apartado, materiales y métodos, se plasman los resultados de la búsqueda de los autores que han aportado al campo de la inteligencia artificial, sobre todo, en el área de las Redes Neuronales Artificiales (RNA), se definen conceptos, el desarrollo que han tenido las RNA, su aportación en los campos del reconocimiento de patrones y en el área de los recursos humanos. De igual manera, se describe qué tipo de la investigación, el diseño de la misma, identificamos la población objetivo del trabajo y de la misma obtenemos una muestra para el entrenamiento de la RNA, en este sentido se hace una descripción de la muestra y el por qué la selección de la muestra, describimos como generar los datos de entrada de la RNA a partir de la muestra seleccionada y se hace una representación funcional de las RNA y los datos de e/salida. establecemos la arquitectura de la RNA considerando el Número de Neuronas de en la Capa de Entrada y el Número de Neuronas en la Capa de Salida.

En el tercer apartado, resultados y discusión, se describe cómo es que se obtuvo la información de la base datos y se relata la manera en que dichos datos se convirtieron en una red neuronal, para el entrenamiento de la red utilizamos un programa llamado BrainMaker, este software fue desarrollado por el California Scientific Software (Software Científico de California).

Para finalizar, se analizan los resultados obtenidos del entrenamiento de la red neuronal artificial diseñada, y se plantean futuras investigaciones en el campo de los recursos humanos, además se hacen recomendaciones para que las unidades administrativas involucradas en la programación del presupuesto establezcan un mecanismo que resuelva las necesidades que se presentan a lo largo del ciclo escolar sin que esto sea un problema para una mejor distribución y aplicación del mismo.

Actualmente, el sistema educativo estatal consta de 204 planteles que atienden a 14988 alumnos, la tabla No. 1 muestra la cantidad de centros de trabajo por nivel que dependen de la unidad administrativa, el número de trabajadores y la cantidad de alumnos en cada uno de ellos.

Tabla 1 Estadísticas del Sistema Educativo Estatal

| Nivel | No. De Ct | No. De Trabajadores | No. Alumnos |
|-------------------------------|------------|---------------------|--------------|
| Preescolar | 26 | 217 | 1846 |
| Primaria | 40 | 524 | 5677 |
| Secundaria | 15 | 718 | 4017 |
| Telesecundaria | 33 | 195 | 1750 |
| Centros de economía domestica | 90 | 227 | 1698 |
| TOTAL: | 204 | 1881 | 14988 |

Nota: muestra la cantidad de centros de trabajo, número de trabajadores y alumnos por nivel educativo
Fuente: elaboración propia

Para atender tal cantidad de alumnos, el Gobierno del Estado, tiene una plantilla de 1881 trabajadores, de los cuales, 124 son directivos, 1210 se desempeñan como docentes frente a grupo y 547 laboran como personal de apoyo y asistencia a la educación. Existen 6 diferentes maneras en las que un trabajador puede ser contratado para trabajar en alguno de los planteles adscritos al Sistema Educativo Estatal, cada uno de ellos tienen sus derechos, prestaciones y obligaciones, para el presente trabajo, solamente tomaremos en cuenta aquellos que, por licencia médica, puedan ser susceptibles de sustitución, estos son, personal de base (01) o interinos ilimitados (04), cabe mencionar que, salvo excepciones, las incapacidades por gravidez se sustituyen en aquellos casos que por necesidad del servicio así lo requiera sin importar el tipo de contratación.

Como parte esencial al momento de elaborar los presupuestos para el pago de personal docente y de apoyo y asistencia a la educación dependiente del Gobierno del Estado es la plantilla de personal de cada uno de los centros de trabajo dependientes del Sistema Educativo Estatal, con esa información se puede hacer una proyección con base en los tabuladores vigentes, los tipos de contratación y los montos del incremento salarial, ya con esto se realiza el presupuesto para pagos de nóminas.

En este sentido, existe un apartado que resulta difícil de calcular, la bolsa de sustituciones, dicha bolsa debe proveer el dinero necesario para cubrir los pagos del personal eventual, es decir, de aquellos que llegan a ocupar una plaza debido a una licencia médica; resulta complicado el hacer estimaciones

exactas de dicha cantidad, lo que normalmente se hace es que, de lo destinado en el presupuesto del año inmediato anterior sólo se le agrega un porcentaje determinado con base en la inflación.

Cabe hacer mención que esta investigación se enmarcó en Línea de Generación y Aplicación del Conocimiento (LGAC) denominada Gestión Educativa del Instituto Superior de Educación Normal del Estado de Colima “Profr. Gregorio Torres Quintero” ya que se busca publicar estudios sobre los procesos de la vida cotidiana en las escuelas y los sistemas y políticas educativas, para identificar rasgos, características y aspectos que obstaculizan o favorecen mejores resultados, de igual manera, se trabajó de manera colaborativa con docentes del Tecnológico Nacional de México quienes coadyuvaron en el análisis de la información para el diseño de la red.

El objetivo general del presente trabajo es el de diseñar una red neuronal que permita analizar el ausentismo laboral de los trabajadores dependientes del sistema educativo estatal, las sustituciones que por licencia médica se extiendan y que eficiente la programación del presupuesto para el pago de suplencias. De esto, se desprenden tres objetivos específicos:

- Determinar con un 95% de efectividad el nivel educativo en dónde se requiere de mayor presupuesto para el pago de suplencias
- Establecer la correlación entre el absentismo laboral y el nivel de logro académico de los alumnos pertenecientes a las escuelas de educación básica del sistema educativo estatal.
- Hacer un análisis de las enfermedades que se dan por mes para trabajar un plan integral con la Secretaría de Salud para la prevención de las mismas.

MATERIALES Y MÉTODOS

En este apartado se establecen las bases teórico conceptuales que marcarán el rumbo de la investigación, se definen conceptos, términos y se hace una descripción de los orígenes, clasificaciones y parámetros de una red neuronal, para comenzar se puede mencionar que las Redes Neuronales son, de acuerdo con, (Marín Diazaraque, 2019), una simulación abstracta de los sistemas nerviosos biológicos, constituidos por un conjunto de unidades llamadas neuronas o nodos conectados unos con otros. El primer modelo de red neuronal fue propuesto en 1943 por McCulloch y Pitts en términos de un modelo computacional de actividad nerviosa. Este modelo era un modelo binario, donde cada neurona tenía un escalón o umbral prefijado, y sirvió de base para los modelos posteriores.

Para esta investigación, nos avocaremos al desarrollo de las redes neuronales artificiales que, con base en (Matich, 2001), estas no son más que otra forma de emular ciertas características propias de los humanos, como la capacidad de memorizar y de asociar hechos. Si se examinan con atención aquellos problemas que no pueden expresarse a través de un algoritmo, se observará que todos ellos tienen una característica en común: la experiencia. El hombre es capaz de resolver estas situaciones acudiendo a la experiencia acumulada. Así, parece claro que una forma de aproximarse al problema consista en la construcción de sistemas que sean capaces de reproducir esta característica humana.

En definitiva, las redes neuronales no son más que un modelo artificial y simplificado del cerebro humano, que es el ejemplo más perfecto del que disponemos para un sistema que es capaz de adquirir conocimiento a través de la experiencia. Una red neuronal es “un nuevo sistema para el tratamiento de la información, cuya unidad básica de procesamiento está inspirada en la célula fundamental del sistema nervioso humano: la neurona”

Definición de Redes Neuronales Artificiales

Las RNA son sistemas de procesamiento de la información cuya estructura y funcionamiento están inspirados en las redes neuronales biológicas (Hilera, 1995). Consisten en un gran número de elementos simples de procesamiento llamados nodos o neuronas que están organizados en capas. Cada neurona está conectada con otras neuronas mediante enlaces de comunicación, cada uno de los cuales tiene asociado un peso. Los pesos representan la información que será usada por la red neuronal para resolver un problema determinado.

De acuerdo a (Palmer & Montaña, 2019), las RNA son sistemas adaptativos que aprenden de la experiencia, esto es, aprenden a llevar a cabo ciertas tareas mediante un entrenamiento con ejemplos ilustrativos. Es a través de este entrenamiento o aprendizaje que las RNA crean su propia representación interna del problema, por tal motivo se dice que son autoorganizadas. Posteriormente, pueden responder adecuadamente cuando se les presentan situaciones a las que no habían sido expuestas anteriormente, es decir, las RNA son capaces de generalizar de casos anteriores a casos nuevos.

Esta característica es fundamental ya que permite a la red responder correctamente no sólo ante informaciones novedosas, sino también ante informaciones distorsionadas o incompletas. En las RNA el tipo de procesamiento de la información es en paralelo, en el sentido de que muchas neuronas pueden



estar funcionando al mismo tiempo. De hecho, nuestro cerebro está compuesto por unas 10^{11} neuronas, las cuales operan en paralelo. Es ahí donde reside una parte fundamental de su poder de procesamiento. Aunque individualmente las neuronas sean capaces de realizar procesamientos muy simples, ampliamente interconectadas a través de las sinapsis (cada neurona puede conectarse con otras 10.000 en promedio) y trabajando en paralelo pueden desarrollar una actividad global de procesamiento impresionante

En resumen, las redes neuronales artificiales consisten en unidades de procesamiento que intercambian datos o información, se utilizan para conocer patrones incluyendo imágenes, manuscritos y secuencias de tiempo, tienen capacidad para aprender y mejorar su funcionamiento.

Según (Lara, 2019), la neurona artificial es una unidad procesadora con cuatro elementos funcionales:

- El receptor, a donde llegan una o varias señales de entrada x_i , que generalmente provienen de otras neuronas y que son atenuadas o amplificadas cada una de ellas con arreglo a un factor de peso w_i que constituye la conectividad entre la neurona fuente de donde provienen y la neurona de destino en cuestión.
- El sumador, que efectúa la suma algebraica ponderada de las señales de entrada, ponderándolas de acuerdo con su peso, aplicando la siguiente expresión:
- La función activadora, que aplica una función no lineal de umbral (que frecuentemente es una función escalón o una curva logística) a la salida del sumador para decidir si la neurona se activa, disparando una salida o no.
- El elemento de salida que es el que produce la señal, de acuerdo con el elemento anterior, que constituye la salida de la neurona.

El receptor y las señales de salida pueden ser señales binarias (0,1 – neuronas de McCulloch y Pitts), bipolares (-1,1), números enteros o continuos, variables borrosas, etc. La regla de propagación suele ser una suma ponderada del producto escalar del vector de entrada y el vector de pesos:

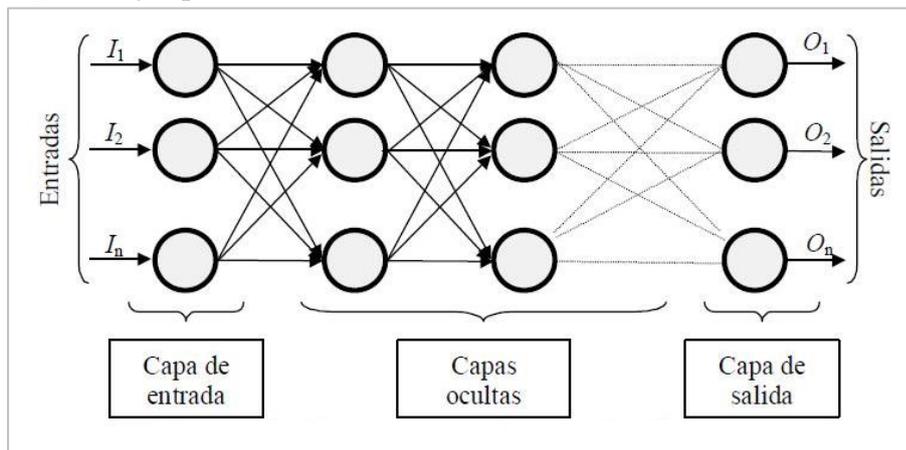
$$h_i(t) = \sum w_{ij}x_j$$

También se usa a menudo la distancia euclidiana entre ambos vectores.

De acuerdo a (Martín, 2007) (Pino, 2001), los elementos básicos de una red neuronal artificial, son los siguientes:

- Neuronas de entrada (capa de entrada): Es quien recibe información del exterior. En las redes biológicas, esta sería tarea de las dendritas.
- Neuronas de salida (capa de salida): Proporciona el resultado del trabajo de la red al exterior y envía información hacia otras neuronas. En las redes biológicas, esta sería una actividad realizada por el axón.
- Neuronas intermedias (capas ocultas): La cuáles están encargadas de realizar el trabajo de la red. En las redes biológicas, está sería el soma.
- Conjunto de conexiones o pesos sinápticos entre las neuronas

Figura 1 Ejemplo de una red neuronal totalmente conectada



Nota: muestra un ejemplo de lo que es una red neuronal totalmente conectada, con su capa de entrada, las capas ocultas y la capa de salidas. Fuente: Elaboración propia con información de Hilera (1995)

Según (Hilera, 1995), las principales características de las RNA son muy similares a las de una Red Neuronal Biológica, entre las que destacan las siguientes:

- Aprenden a través de ejemplos.
- Inferencia estadística.
- Adaptabilidad.
- Dilema plasticidades y estabilidad.
- Capacidades de generalización.
- Tolerante a fallas.
- Rápida implantación

Clasificación de las RNA

Con base en la bibliografía consultada, existen diferentes maneras de clasificar las RNA, Redes Unicapa, multicapa, Híbridas, Supervisadas, No Supervisadas, en lo personal, la clasificación que hace (Charytoniuk, 2000) es la que mejor se adapta a los objetivos de esta investigación, las clasifica según su arquitectura, tipo de aprendizaje y sus aplicaciones.

(Larrañaga & Inza, 2019) mencionan que teniendo en cuenta diversos conceptos se pueden establecer diferentes tipos de arquitecturas neuronales. Así considerando su estructura podemos hablar de redes monocapa –compuestas por una única capa de neuronas– o redes multicapa –las neuronas se organizan en varias capas–. Teniendo en cuenta el flujo de datos, podemos distinguir entre redes unidireccionales (feedforward) y redes recurrentes o realimentadas (feedback). Mientras que en las redes unidireccionales la información circula en un único sentido, en las redes recurrentes o realimentadas la información puede circular entre las distintas capas de neuronas en cualquier sentido, incluso en el de salida-entrada.

Como ya lo mencionamos en el apartado anterior, este tipo de RNA son las que tienen conexiones hacia adelante y en un solo sentido, de acuerdo con el número de capas pueden ser Monocapa y Multicapa, las primeras cuentan con una sola capa de neuronas que proyectan las entradas a una capa de neuronas de salida, donde se realizan diferentes cálculos; las más conocidas son Monolayer Perceptron y el ADALINE. En tanto, la segunda de ellas, como su nombre lo indica, existe más de una capa entre la entrada y la salida, las más conocidas son Multilayer Perceptron y el -ADALINE. En las figuras 6 y 7 podemos observar cómo es que se comportan las RNA antes mencionadas

La principal característica son las conexiones de retorno entre neuronas de una determinada capa con otras de capas anteriores, conexiones entre neuronas una misma capa o conexiones de una neurona consigo misma. Entre las más conocidas con esta arquitectura se encuentran las SOM de Kohonen, Hopfield y las redes ART. La figura número 8 ilustra de mejor manera lo que se mencionó anteriormente.

(Calvo, 2019), menciona que el aprendizaje supervisado se caracteriza porque el mismo se realiza mediante un entrenamiento controlado por un supervisor que determina la respuesta que se debe generar



para cada entrada. El supervisor controla la salida y si esta no es correcta, modifica los pesos de las conexiones, con el fin de que la salida obtenida se aproxime a la deseada

Siguiendo con (Calvo, 2019), el aprendizaje no supervisado se caracteriza porque no requieren influencia externa para ajustar los pesos, busca encontrar las características, regularidades, correlaciones o categorías que se puedan establecer entre los datos que se presenten como entrada. La interpretación de sus datos depende de su estructura y del algoritmo de aprendizaje empleado.

La salida podía representar el grado de similitud entre los datos, un clustering o establecimiento de categorías.

La clasificación propuesta de las redes neuronales con base en la aplicación que se les da, es la siguiente:

- Reconocimiento de Patrones, son del tipo no recurrente y con aprendizaje supervisado.
- Clasificación, hacen uso del aprendizaje no supervisado para obtener características de clasificación a base de las entradas del problema.
- Predicción, tienen como objetivo modelar una función no lineal.
- Memoria Asociativa. Aprender es el proceso donde se forman asociaciones entre patrones relacionados. Asociamos patrones con la misma modalidad sensitiva (imagen visual con otra imagen) o con tipos diferentes (un olor con una imagen).
- Mapeo de Características.
- Optimización.

Como ya lo mencionamos anteriormente (Pino, 2001), para la creación de una red neuronal artificial se consideran ciertos parámetros topológicos, los cuales se describen a continuación:

N: Número de neuronas en la capa de entrada.

Y: Número de neuronas en la capa de salida.

O: Número de neuronas en la capa oculta.

W_{ij} : Peso sináptico de la neurona i hacia la neurona j .

Algoritmo de Aprendizaje

Para el entrenamiento de las redes neuronales artificiales los algoritmos más comunes son el Backpropagation y todas sus variantes, dichos algoritmos constan de dos etapas, la primera se refiere al Aprendizaje o Entrenamiento, aquí se requieren los datos de entrada y salida, el algoritmo de

aprendizaje se encarga de generar una función que los vincule, la siguiente etapa se denomina de Recuerdo o Reconocimiento en donde se solicitan los datos de entrada y la RNA utilizando la función generada en la fase de aprendizaje genera los datos de salida. En el siguiente apartado se profundizará en este tema.

Un Perceptrón multicapa es una red con alimentación hacia delante, compuesta de varias capas de neuronas entre la entrada y la salida de la misma, esta red permite establecer regiones de decisión mucho más complejas que las de dos semiplanos, como lo hace el Perceptrón de un solo nivel.

La salida de la red está dada por:

$$a = \text{hardlim}(W * p + b)$$

Donde:

W: Matriz de pesos asignada a cada una de las entradas de la red de dimensiones $S \times R$, con S igual al número de neuronas, y R la dimensión del vector de entrada

p: Vector de entradas a la red de dimensiones $R \times 1$

b: Vector de ganancias de la red de dimensiones $S \times 1$

En la segunda columna se muestra el tipo de región de decisión que se puede formar con cada una de las configuraciones, en la siguiente se indica el tipo de región que se formaría para el problema de la XOR, en las dos últimas columnas se muestran las regiones formadas para resolver el problema de clases mezcladas y las formas más generales para cada uno de los casos.

El Perceptrón básico sólo puede establecer dos regiones separadas por una frontera lineal en el espacio de entrada de los patrones; un Perceptrón con dos capas, puede formar cualquier región convexa en este espacio. Las regiones convexas se forman mediante la intersección de regiones formadas por cada neurona de la segunda capa, cada uno de estos elementos se comporta como un Perceptrón simple, activándose su salida para los patrones de un lado del hiperplano, si el valor de los pesos de las conexiones entre las neuronas de la segunda capa y una neurona del nivel de salida son todos igual a 1, y la función de salida es de tipo hardlim, la salida de la red se activará sólo si las salidas de todos los nodos de la segunda capa están activos, esto equivale a ejecutar la función lógica AND en el nodo de salida, resultando una región de decisión intersección de todos los semiplanos formados en el nivel anterior.

La región de decisión resultante de la intersección será una región convexa con un número de lados a lo sumo igual al número de neuronas de la segunda capa. A partir de este análisis surge el interrogante respecto a los criterios de selección para las neuronas de las capas ocultas de una red multicapa, este número en general debe ser lo suficientemente grande como para que se forme una región compleja que pueda resolver el problema, sin embargo, no debe ser muy grande pues la estimación de los pesos puede ser no confiable para el conjunto de los patrones de entrada disponibles.

Hasta el momento no hay un criterio establecido para determinar la configuración de la red y esto depende más bien de la experiencia del diseñador. La regla de aprendizaje del Perceptrón para una red multicapa es una generalización de:

$${}_iW^{\text{nuevo}} = {}_iW^{\text{anterior}} + e p^T$$

$$b^{\text{nueva}} = b^{\text{anterior}} + e$$

Algoritmo Backpropagation

La regla de aprendizaje del Perceptrón de Rosenblatt y el algoritmo LMS de Widrow y Hoff fueron diseñados para entrenar redes de una sola capa. Estas redes tienen la desventaja que solo pueden resolver problemas linealmente separables, fue esto lo que llevo al surgimiento de las redes multicapa para sobrepasar esta dificultad en las redes hasta entonces conocidas.

El primer algoritmo de entrenamiento para redes multicapa fue desarrollado por Paul Werbos en 1974, este se desarrolló en un contexto general, para cualquier tipo de redes, siendo las redes neuronales una aplicación especial, razón por la cual el algoritmo no fue aceptado dentro de la comunidad de desarrolladores de redes neuronales. Fue solo hasta mediados de los años 80 cuando el algoritmo Backpropagation o algoritmo de propagación inversa fue redescubierto al mismo tiempo por varios investigadores, David Rumelhart, Geoffrey Hinton y Ronal Williams, David Parker y Yann Le Cun. El algoritmo se popularizó cuando fue incluido en el libro "Parallel Distributed Processing Group" por los psicólogos David Rumelhart y James McClelland. La publicación de este libro trajo consigo un auge en las investigaciones con redes neuronales, siendo la Backpropagation una de las redes más ampliamente empleadas, aun en nuestros días.

Uno de los grandes avances logrados con el algoritmo Backpropagation es que esta red aprovecha la naturaleza paralela de las redes neuronales para reducir el tiempo requerido por un procesador



secuencial para determinar la correspondencia entre unos patrones dados. Además, el tiempo de desarrollo de cualquier sistema que se esté tratando de analizar se puede reducir como consecuencia de que la red puede aprender el algoritmo correcto sin que alguien tenga que deducir por anticipado el algoritmo en cuestión.

La regla o algoritmo de aprendizaje es el mecanismo mediante el cual se van adaptando y modificando todos los parámetros de la red. En el caso del Perceptrón multicapa se trata de un algoritmo de aprendizaje supervisado, es decir, la modificación de los parámetros se realiza para que la salida de la red sea lo más próxima posible a la salida proporcionada por el supervisor o salida deseada. Por tanto, para cada patrón de entrada a la red es necesario disponer de un patrón de salida deseada.

El algoritmo Backpropagation emplea un ciclo propagación – adaptación de dos fases. Una vez que se ha aplicado un patrón a la entrada de la red como estímulo, este se propaga desde la primera capa a través de las capas superiores de la red, hasta generar una salida. La señal de salida se compara con la salida deseada y se calcula una señal de error para cada una de las salidas.

Las salidas de error se propagan hacia atrás, partiendo de la capa de salida, hacia todas las neuronas de la capa oculta que contribuyen directamente a la salida. Sin embargo, las neuronas de la capa oculta solo reciben una fracción de la señal total del error, basándose aproximadamente en la contribución relativa que haya aportado cada neurona a la salida original. Este proceso se repite, capa por capa, hasta que todas las neuronas de la red hayan recibido una señal de error que describa su contribución relativa al error total. Basándose en la señal de error percibida, se actualizan los pesos de conexión de cada neurona, para hacer que la red converja hacia un estado que permita clasificar correctamente todos los patrones de entrenamiento.

La importancia de este proceso consiste en que, a medida que se entrena la red, las neuronas de las capas intermedias se organizan a sí mismas de tal modo que las distintas neuronas aprenden a reconocer distintas características del espacio total de entrada. Después del entrenamiento, cuando se les presente un patrón arbitrario de entrada que contenga ruido o que esté incompleto, las neuronas de la capa oculta de la red responderán con una salida activa si la nueva entrada contiene un patrón que se asemeje a aquella característica que las neuronas individuales hayan aprendido a reconocer durante su



entrenamiento. Y a la inversa, las unidades de las capas ocultas tienen una tendencia a inhibir su salida si el patrón de entrada no contiene la característica para reconocer, para la cual han sido entrenadas.

Varias investigaciones han demostrado que, durante el proceso de entrenamiento, se tiende a desarrollar relaciones internas entre neuronas con el fin de organizar los datos de entrenamiento en clases. Esta tendencia se puede extrapolar, para llegar a la hipótesis consistente en que todas las unidades de la capa oculta son asociadas de alguna manera a características específicas del patrón de entrada como consecuencia del entrenamiento.

Lo que sea o no exactamente la asociación puede no resultar evidente para el observador humano, lo importante es que la red ha encontrado una representación interna que le permite generar las salidas deseadas cuando se le dan las entradas, en el proceso de entrenamiento. Esta misma representación interna se puede aplicar a entradas que la red no haya visto antes, y la red clasificará estas entradas según las características que compartan con los ejemplos de entrenamiento.

Principales Problemas del Backpropagation

Velocidad de convergencia. El algoritmo Backpropagation es lento y se han propuesto muchas modificaciones y variantes para mejorar la velocidad del entrenamiento. Algunas se reflejan en el apartado de variantes, y otras se incluyen en las lecturas sobre el tema.

Mínimos Locales. El método del gradiente descendente a veces queda “atrapado” en un mínimo local, del que no puede salir, y por tanto el aprendizaje no se hace bien. Una forma de obviar esto es realizar el aprendizaje varias veces, partiendo de pesos diferentes cada vez, y seleccionar la ejecución que mejor resuelve el problema. Algunas de las variantes buscan usar otros procesos de optimización no lineal más seguros que el gradiente descendente.

Sobre entrenamiento. Es el problema de que se aprende muy bien los ejemplos de entrenamiento, pero cuando se usa la RNA entrenada, con muestras que no ha aprendido, no es capaz de dar buenas respuestas. Se puede evitar seleccionando muy bien el conjunto de entrenamiento y parando el entrenamiento cuando el error es suficientemente pequeño, pero no excesivamente pequeño. Se dice entonces, que la RNA no generaliza bien.

Saturación. Se puede producir cuando las salidas esperadas en cada neurona de salida son 0 o 1. Al pretender acercar las salidas de la Red a estos valores, nos ponemos en zonas donde la función de

activación tiene tangente de pendiente casi cero y entonces no se produce apenas modificación de los pesos y por tanto del error. La forma de resolverlo es cambiar los valores de salidas esperadas a 0.1 y 0.9 . Esto puede requerir adaptación de los datos reales. También se produce si los pesos se hacen muy grandes, porque los resultados de la Red ya no varían.

Estabilidad o robustez. Un tema interesante y actual, sobre todo para implementaciones hardware de la RNA entrenada, es la estabilidad del aprendizaje sobre variaciones en los pesos (y/o en las entradas). Hay medidas de estabilidad estadística, que se pueden usar para seleccionar la RNA entrenada más estable de entre varias ejecuciones También hay métodos que tienen en cuenta estas medidas en el entrenamiento de la Red, aunque son más lentos.

Taza de Aprendizaje

Para una red multicapa la superficie del error no es una función cuadrática, su forma es diferente para diferentes regiones del espacio, la velocidad de convergencia puede incrementarse por la variación de la tasa de aprendizaje en cada parte de la superficie del error, sin sobrepasar el valor máximo para aprendizaje estable definido anteriormente.

Existen varias técnicas para modificar la tasa de aprendizaje; este algoritmo emplea un procedimiento mediante el cual el rango de aprendizaje varía de acuerdo al rendimiento que va presentando el algoritmo en cada punto; si el error disminuye vamos por el camino correcto y se puede ir más rápido incrementando la tasa de aprendizaje, si el error aumenta, es necesario decrementar la tasa de aprendizaje; el criterio de variación de α debe estar en concordancia con las siguientes reglas heurísticas:

- Si el error cuadrático de todos los parámetros del set de entrenamiento se incrementa en un porcentaje ζ típicamente entre 1% y 5%, después de la actualización de los pesos, esa actualización es descartada, la tasa de aprendizaje se multiplica por un factor $0 < p < 1$, y el coeficiente de moméntum es fijado en cero.
- Si el error cuadrático se decrementa después de la actualización de los pesos, esa actualización es aceptada y la tasa de aprendizaje es multiplicada por un factor $\eta > 1$.
- Si el moméntum había sido previamente puesto en cero, se retorna a su valor original.
- Si el error cuadrático se incrementa en un valor menor a ζ , los pesos actualizados son aceptados, pero la tasa de aprendizaje y el coeficiente de moméntum no son cambiados.

En las técnicas de gradiente descendiente es conveniente avanzar por la superficie de error con incrementos pequeños de los pesos; esto se debe a que tenemos una información local de la superficie y no se sabe lo lejos o lo cerca que se está del punto mínimo, con incrementos grandes, se corre el riesgo de pasar por encima del punto mínimo, con incrementos pequeños, aunque se tarde más en llegar, se evita que esto ocurra.

El elegir un incremento adecuado influye en la velocidad de convergencia del algoritmo, esta velocidad se controla a través de la tasa de aprendizaje α , la que por lo general se escoge como un número pequeño, para asegurar que la red encuentre una solución.

Un valor pequeño de α significa que la red tendrá que hacer un gran número de iteraciones, si se toma un valor muy grande, los cambios en los pesos serán muy grandes, avanzando muy rápidamente por la superficie de error, con el riesgo de saltar el valor mínimo del error y estar oscilando alrededor de él, pero sin poder alcanzarlo.

Se suele usar también un término *momentum* (inercia) en el ajuste de pesos, que acelera la convergencia del algoritmo. Lo que se hace es tener en cuenta el ajuste realizado en la iteración n , para hacer el ajuste en la iteración $n+1$, con un coeficiente del *momentum*, pretende obviar saltos bruscos en las direcciones de optimización que marca el gradiente descendente. El ajuste de los pesos se hace con

$$W(t) = W(t - 1) + \Delta W(t) \text{ /* Sin inercia */}$$

$$W(t) = W(t - 1) + \Delta W(t) + \textit{momentum} * \Delta W(t - 1)$$

Las RNA y sus Aplicaciones en el Área de Recursos Humanos

El algoritmo de retropropagación de errores se ha aplicado a una cantidad ingente de problemas de laboratorio (para verificar las prestaciones) y de la vida real. Su fama se debe sin duda al éxito de gran parte de estas aplicaciones.

En el área de recursos humanos, o la gestión del capital humano al interior de una empresa, se han desarrollado diferentes trabajos en los que se han utilizado las redes neuronales artificiales para la selección de personal (Morales Núñez & Ortega Hernández, 2018), evaluación de competencias laborales (Torres et. al, 2016), Predicción de deserción laboral utilizando algoritmos genéticos y redes neuronales artificiales (Reyes – Huertas, 2019), un último ejemplo -hay muchos más- lo podemos encontrar en Google, que formó un equipo de *People Analytics* para realizar proyectos de análisis de

información de RRHH que respondan a problemas tan complejos como encontrar las características comunes de los Equipos de Trabajo más eficaces (Project Aristotle) o los mejores Líderes (Project Oxygen). Los resultados de muchos de estos estudios pueden encontrarse en rework.withgoogle.com, y han llevado a compañías como Facebook, Amazon, Microsoft y muchas otras a departamentos similares.

En el presente trabajo, se emplearon dos tipos de investigación: básica y aplicada, se hizo una investigación básica para el desarrollo de una nueva forma de calcular el presupuesto destinado al pago de suplencias por licencias médicas, en qué medida afecta el ausentismo laboral al proceso de enseñanza – aprendizaje de las escuelas de nivel básico dependientes del sistema educativo estatal y cómo inferir qué enfermedades son más comunes en cada uno de los meses en un año calendario para trabajar un plan integral de salud con las dependencias correspondientes.

De igual manera, se realizó una investigación aplicada para diseñar una red neuronal artificial que aprenda a reconocer los factores que están involucrados en la investigación básica y así obtener los mejores resultados posibles.

La etapa no experimental tiene que ver con la recolección y análisis de la información contenida en las bases de datos del Gobierno Estatal, las incidencias, tipos de las mismas, el universo de trabajadores y el presupuesto asignado para el pago de suplencias;

Para la segunda etapa, el modelo el diseño experimental se utilizó el modelo de prueba y posprueba con grupos experimentales.

La población está constituida por los 103, 025 registros electrónicos que a lo largo de 10 años se han capturado de los trabajadores que han laborado en alguno de los 203 centros de trabajo dependientes del Sistema Educativo Estatal.

Para el presente trabajo decidimos utilizar los parámetros que marcaba la Ley del Sistema para la Carrera de las Maestras y los Maestros y el Reglamento de la Condiciones Generales de Trabajo del Sistema Educativo Estatal en lo que se refiere a las sustituciones del personal, es decir, sólo se sustituyen las licencias médicas que sean mayores a quince días ya sea por enfermedad general, enfermedad profesional, riesgo de trabajo, cirugía y fractura, de estas, se tomaron los siguientes parámetros para obtener una muestra heterogénea.

Tabla 2 Parámetros utilizados para la obtención de la muestra

| Parámetro | Descripción |
|--------------------------|--|
| Id_CentroTrabajo | Identificador del Centro de Trabajo |
| Id_Medico | Identificador del médico que expide la incapacidad |
| Id_TipoIncidencia | Identificador del Tipo de Incidencia (Falta no justificada, Enfermedad General, Fractura, Riesgo de Trabajo, Gravidéz) |
| Id_DescripcionEnfermedad | Identificador de la Descripción de la Enfermedad (Faringitis, Úlcera, Fractura de Peroné, etc.) |
| Año | Año en el que se generó la incidencia |
| Número de días | Cantidad de días que duró la incidencia |
| Sustitución | Si generó o no sustitución |
| Importe | El pago generado por la sustitución |

Nota: muestra los parámetros utilizados para el diseño de la RNA

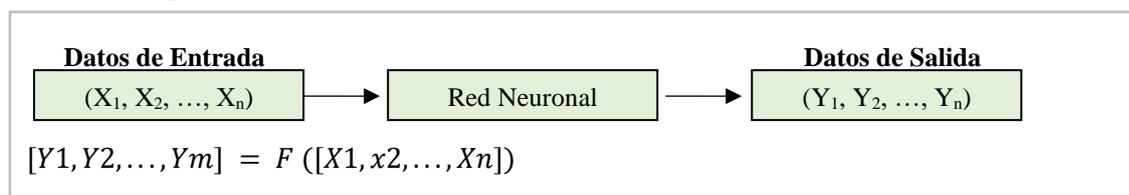
Fuente: elaboración propia

La muestra consta de 89, 443 registros que incluyen sólo los centros de trabajo de educación básica, es decir, aquellos que pertenecen a los niveles de preescolar, primaria, secundaria y telesecundaria, quedando fuera las áreas administrativas y las instituciones de educación media superior y superior. De los tipos de incidencia sólo se tomaron en cuenta las faltas injustificadas, las enfermedades generales, riesgo de trabajo, fractura y cirugía.

Cabe hacer mención que la base de datos cuenta con registros desde el año 2001, sólo que en esa época no se capturaba la descripción de las enfermedades que reportaban los médicos de pensiones, de igual manera, se dejaron de lado aquellas incidencias que no son susceptibles de sustituir ya sea debido a cuestiones normativas o aquellas que no representan un gasto extra en el presupuesto que para la bolsa de sustituciones destina cada año el Gobierno del Estado.

En teoría, la dependencia funcional entre una red neuronal artificial y sus datos de entrada y salida la podemos observar en la figura número 3.

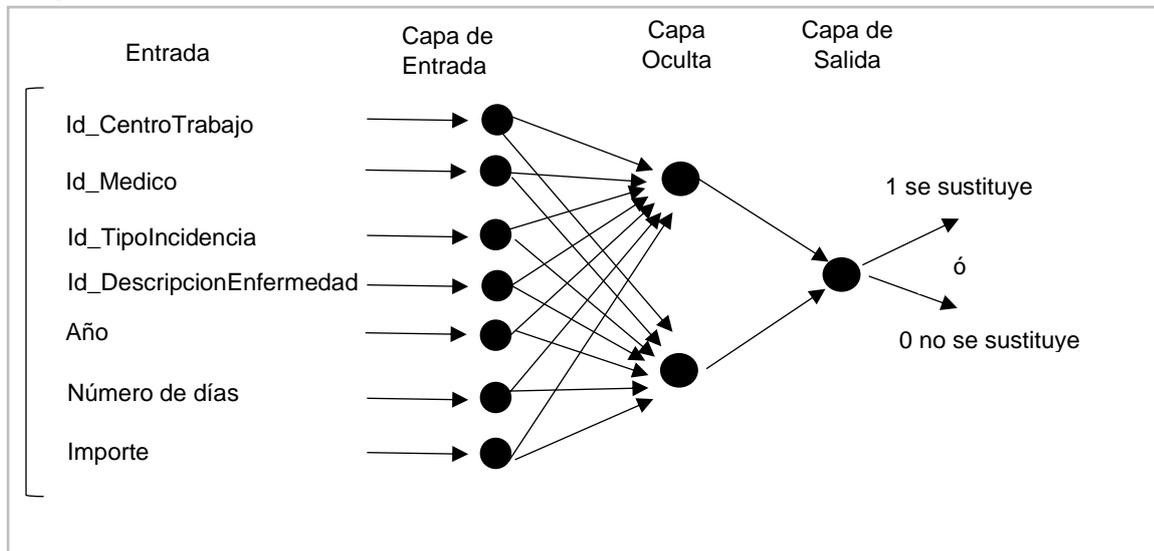
Figura 3 Dependencia funcional de una red neuronal



Fuente: Elaboración propia

Para este trabajo de investigación, la dependencia funcional entre de los datos de entrada y salida y la RNA buscada se muestra en la figura 4.

Figura 4 Diseño de la Red Neuronal Artificial Simeón



Fuente: Elaboración propia

Con base en lo expuesto anteriormente, queda claro que para poder sustituir a una persona es necesario poder comprobar los valores del centro de trabajo, el doctor, el tipo de incidencia, la enfermedad, el importe de la sustitución, el año y los días que se otorgan por cada incidencia, por lo tanto, el número de neuronas en la capa de entrada son 7.

Cada neurona de salida de una red neuronal sirve para reconocer un patrón diferente, el objetivo principal de esta investigación es el de reconocer si una incidencia genera una sustitución, es por eso que solamente se incluyó una neurona en la capa de salida

RESULTADOS Y DISCUSIÓN

En este trabajo de investigación para el desarrollo y entrenamiento de la red neuronal se utilizó un software llamado Brainmaker, de acuerdo con (Brodzinski, 1992), la inteligencia artificial ha sido objeto de miles de esfuerzos de investigación durante los últimos 30 años, un aspecto de la inteligencia artificial, las redes neuronales han recibido recientemente una gran atención, tanto por parte de investigadores como de profesionales en el gobierno y las empresas. De hecho, el 80 por ciento de las compañías que están consideradas por la revista Fortune 500 tiene una inversión actual en redes neuronales.

Una forma económica de experimentar con redes neuronales en una PC es con BrainMaker, este software fue desarrollado por el California Scientific Software (Software Científico de California). El programa se incluye con NetMaker v2.3 que es utilizado para preparar datos para el análisis en BrainMaker. Con NetMaker, ingresa datos en formato ASCII, base de datos o archivos de hoja de cálculo y se puede etiquetar cada variable en el conjunto de datos.

NetMaker crea los archivos de definición, capacitación y de prueba requeridos para ejecutar BrainMaker. BrainMaker entonces "entrena" automáticamente la red hasta que pueda predecir con precisión los resultados definidos en el conjunto de datos la red "entrenada", con esto se puede probar el archivo de prueba creado por NetMaker. BrainMaker también ofrece diagnósticos que permiten a los usuarios ajustar sus redes y mejorar su precisión.

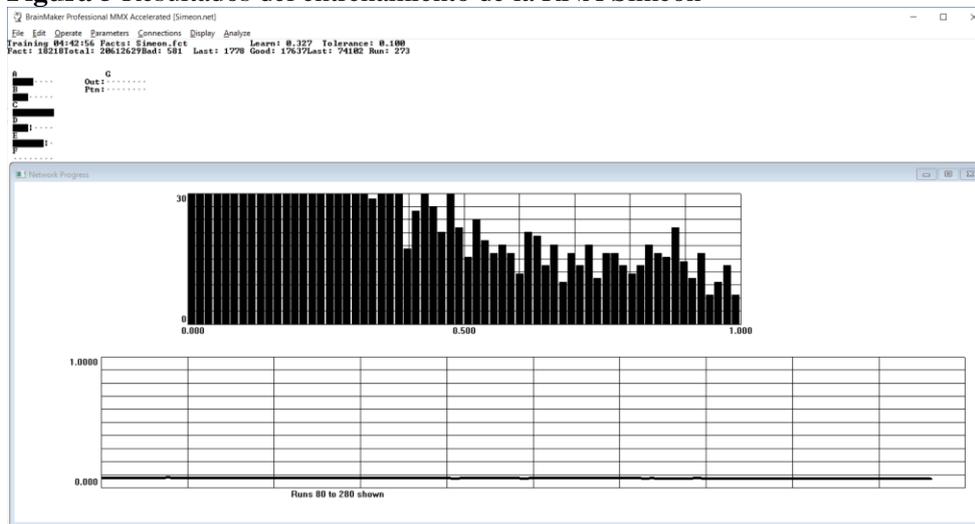
Una vez satisfechos con los resultados, los datos sin procesar se pueden ingresar como un "archivo de ejecución" (un dato archivo sin los resultados previstos incluidos). El "archivo de ejecución" se puede crear en una hoja de cálculo, editor, base de datos y luego formateado en NetMaker. El "archivo de ejecución" es procesado por red neuronal entrenada y da como resultado un archivo de salida que contiene los resultados de la red neuronal.

El primer paso que se debe de hacer para poder crear la red neuronal en Brainmaker es definir la estructura de la misma, por esto, de la base de datos que se desarrolló en el Sistema Educativo Estatal para almacenar la información referente a las incidencias que son generadas por los trabajadores adscritos a los centros de trabajo dependientes del mismo, se toma la información referente a las tablas incidencias, médicos, enfermedades, descripción de las enfermedades, centros de trabajo y claves presupuestales afectadas, cabe mencionar que hasta antes de marzo del año 2019, la unidad administrativa que gestiona los pagos contaba con solo 100 claves de pago, motivo por el cual más de algunos de los 203 centros de trabajo estaban agrupados en esas 100 claves de pago, a partir de abril de 2019 se autorizó la creación de una clave de pago por cada uno de los centros de trabajo que están adscritos al Sistema Educativo Estatal. Una vez recuperados los datos, se importaron a un archivo de Excel el cual se guardó con el formato de texto con separaciones por tabulación en el disco duro con el nombre Simeon.txt.

A continuación, se describen los pasos para importar dicha estructura al software Brainmaker:

1. Ejecutar el programa llamado Netmaker
2. Seleccionar la opción “Read in Data File” (Leer un archivo de datos)
3. Utilizar el archivo que previamente creado (Simeon.txt)
4. Designar para cada columna el atributo que se necesitaba, a excepción de la columna sustitución que fue considerada como patrón, todas las demás columnas son señaladas como datos de entrada.
5. Guardar los datos como un archivo de netmaker.
6. Abrir Brainmaker, seleccionar entrenar la red y esperar por unos minutos para que se entrene la red, los resultados se muestran en la figura número 5.

Figura 5 Resultados del entrenamiento de la RNA Simeón



Fuente: obtenida del software Brainmaker

CONCLUSIÓN

Antes que nada, debo mencionar que este es un trabajo inédito en la historia de la administración pública, sienta las bases para una mejor programación del presupuesto que para el pago de suplencias destina cada año el Gobierno del Estado, no supone una tarea fácil puesto que para la planeación del mismo deben de intervenir varias unidades administrativas.

En un entorno en el cual se están implementando medidas de austeridad y un manejo inteligente de los recursos públicos era necesario el desarrollo de una investigación como esta, en la que se tomará en cuenta las necesidades que se generan en cada ciclo escolar debido a licencias médicas, tomando como referencia el estado de (GEC, 2019), en la partida número 12204, llamada “Pago de suplencias

Magisterio”, se destina la cantidad de \$ 13,361,625.00 (Trece millones trescientos sesenta y un mil seiscientos veinticinco pesos), cabe resaltar que esta cantidad resulta de la aplicación del porcentaje de incremento de la inflación del ciclo fiscal anterior.

Entre las ventajas que presentan las redes neuronales artificiales con las estadísticas destacan el excelente rendimiento que presentan las primeras ante problemas no lineales o información con mucho ruido, en este caso, la autoridad desconoce cuántas, cuáles y el número de días que deberá de pagar por las sustituciones que se presenten en el sistema educativo estatal, Simeón puede inferir, con base en la información proporcionada, cuáles serán las enfermedades que más se presenten a lo largo del ciclo fiscal y quiénes son los más susceptibles a presentarlas. Es decir, no es lo mismo que se enferme un docente frente a grupo que una persona que realice funciones administrativas, la Ley General de Educación antepone el derecho de las niñas y los niños a recibir educación, en este sentido, es muy probable que sí se sustituya la primera y no es tan necesaria la segunda.

De igual manera, al contener en la Red Neuronal Artificial la información de las enfermedades, se puede incluir a la Secretaría de Salud para que, conforme a los meses del año y a la incidencia de ciertas enfermedades, elabore un plan integral para prevenir dichas enfermedades, además de aprovisionarse con medicamentos, doctores y todo lo relacionado con su área de trabajo.

En el mismo sentido, la Secretaría de Educación obtiene una herramienta de apoyo para mitigar los efectos que por dichas ausencias pueda sufrir el proceso de enseñanza aprendizaje en los alumnos de educación básica, debe de realizar una reingeniería en el proceso de contratación de los docentes o del personal de apoyo y asistencia a la educación para que dicho trámite sea lo más ágil y transparente posible.

REFERENCIAS BIBLIOGRÁFICAS

Brodzinski, J. D. (1992). BrainMaker v2.3. *Journal of International Information Management*, 1-2.

Calvo, D. (28 de Septiembre de 2019). diegocalvo.es. Obtenido de <http://www.diegocalvo.es/clasificacion-de-redes-neuronales-artificiales/>

Charytoniuk, W. (2000). Neural-network-based demand forecasting in a deregulated environment. *Industry Applications*, 893-898.



- Gobierno del Estado de Colima GEC (2019). Gobierno del Estado de Colima. Obtenido de col.gob.mx:
http://www.col.gob.mx/transparencia/archivos/portal/2018012508371162_Presupuesto-egresos-Colima-2018.pdf
- Hilera, J. y. (1995). Redes neuronales artificiales: Fundamentos, modelos y aplicaciones. Madrid: Rama.
- Lara Rosano, F. (27 de Septiembre de 2019). FUNDAMENTOS DE REDES. Ciudad de México, Ciudad de México, México.
- Larrañaga, P., & Inza, I. y. (28 de Septiembre de 2019). Departamento de Ciencias de la Computación e Inteligencia Artificial. Obtenido de Universidad del País Vasco:
<http://www.sc.ehu.es/ccwbayes/docencia/mmcc/docs/t8neuronales.pdf>
- Marín Diazaraque, J. M. (2019). Introducción a las redes neuronales. Madrid: Universidad Carlos III de Madrid.
- Martin, B. y. (2007). Redes Neuronales y Sistemas Borrosos. Madrid: Alfaomega.
- Matich, D. J. (2001). Redes Neuronales: Conceptos Básicos y Aplicaciones. Rosario, Argentina: Universidad Tecnológica Nacional – Facultad Regional Rosario .
- Morales Núñez, C. A., & Ortega Hernández, A. (2018). MEJORA DEL PROCESO DE SELECCIÓN DE PERSONAL MEDIANTE LA APLICACIÓN DE REDES NEURONALES: UN CASO DE ESTUDIO EN EL SECTOR TEXTIL. Pistas Educativas, 2250-2265.
- PALMER POL, A., & MONTAÑO MORENO, J. (19 de Octubre de 2019). ¿Qué son las redes neuronales artificiales? Islas Baleares, Islas Baleares, España.
- Pino, R. G. (2001). Introducción a la Inteligencia Artificial: Sistemas Expertos, Redes Neuronales Artificiales y Computación Evolutiva. Oviedo: Universidad de Oviedo.
- Reyes-Huertas, G. (2019). Predicción de deserción laboral utilizando un algoritmo genético y redes neuronales artificiales. Interfases, 12(012), 32-48.
<https://doi.org/10.26439/interfases2019.n012.4636>
- Torres López, Surayne, Lazara Aldana Cuza, Miroslava, Piñero Pérez, Pedro Y. & Piedra Diéguez, Laynier A. (2016). Red neuronal multicapa para la evaluación de competencias laborales. Revista Cubana de Ciencias Informáticas. Vol. 10, No. Especial UCIENCIA, Noviembre, 2016

