

# RED NEURONAL BASADA EN INTELIGENCIA ARTIFICIAL PARA REDUCIR EL TIEMPO DE DIAGNÓSTICO DE NEUMONÍA MEDIANTE RADIOGRAFÍAS DE TÓRAX

## NEURONAL NETWORK BASED ON ARTIFICIAL INTELLIGENCE TO REDUCE THE TIME OF PNEUMONIA DIAGNOSIS THROUGH CHEST X-RADIOGRAPHS

VARGAS VILLAGÓMEZ A.

### RESUMEN

Ua medicina es uno de los campos del conocimiento que más podrían beneficiarse con la interacción cercana de la computación, mediante la cual se optimizarían procesos complejos e imperfectos como el diagnóstico diferencial. De esto se ocupa el aprendizaje automático, rama de la inteligencia artificial que construye y estudia sistemas capaces de aprender, a partir de un conjunto de datos de adiestramiento, y de mejorar procesos de clasificación y predicción. La neumonía es un tipo de infección respiratoria aguda que afecta a los pulmones. En Bolivia entre los años 2018 y 2019 se registró un incremento del 66% en casos de neumonías entre menores de uno a cinco años, afirmando, también, que ésta es una de las principales causas de mortalidad infantil. Introduciendo una red neuronal al diagnóstico de neumonía se produciría una reducción del tiempo de diagnóstico. Por lo anterior se determinarán los requerimientos fundamentales del sistema, se elaborará un algoritmo de Red Neuronal, se diseñará la interfaz gráfica, se realizará una selección de herramientas mediante los estudios técnicos de PMBOOK V6. También se realizará el entrenamiento y evaluación de la red neuronal con estructuras de entrenamiento brindadas por TensorFlow. Se pretende tener un porcentaje de acierto en la red neuronal de 90 %. Se logró un promedio de aciertos: para pacientes con neumonía 83,4% y para pacientes sanos 84,4 %, además, mediante el uso de diagramas de procesos y cálculo de tiempo se observó una disminución del tiempo de diagnóstico en un 75%

### PALABRAS CLAVE

Red Neuronal. Diagnóstico. Neumonía.

### ABSTRACT

Medicine is one of the fields of knowledge that could benefit the most from a close interaction with computing, through which complex and imperfect processes such as differential diagnosis would be optimized. This is what automatic learning deals with, a branch of artificial intelligence that builds and studies systems capable of learning from a set of training data and from improving classification and prediction processes. Pneumonia is a type of acute respiratory infection that affects the lungs. In Bolivia, between 2018 and 2019, there was an increase of 66% in cases of pneumonia among children between the ages of one and five, also stating that this is one of the main causes of infant mortality. Introducing a neural network to the diagnosis of pneumonia produces a reduction in the diagnosis time. The fundamental requirements of the system were determined. The Neural Network algorithm was developed. The graphical interface was designed. Optimal selection of tools was made using PMBOOK V6 technical studies. The training and evaluation of the neural network was carried out with training structures provided by TensorFlow. The maximum percentage of success in the neural network is 90%. An average of correct answers was achieved: 83.4% for patients with pneumonia and 84.4% for healthy patients, in addition, through the use of process diagrams and time calculation, a 75% reduction in diagnosis time was observed.

### KEYWORDS

Neural Network. Diagnosis. Pneumonia.

## INTRODUCCIÓN

**D**esde el origen de las computadoras digitales se han hecho investigaciones y desarrollos tecnológicos con la finalidad de facilitar algunas actividades propias de los seres humanos.

Se han logrado automatizar muchos procesos mecánicos, de cálculo, de almacenamiento de datos, de procesamiento, etc., desarrollando, cada vez, herramientas de cómputo capaces de auxiliar en forma directa cada una de estas actividades.

El ser humano mediante el uso de los sentidos, puede enterarse de hechos que suceden en el medio ambiente que lo rodea y es capaz de establecer relaciones entre ellos para obtener conclusiones, desarrollar conocimiento y actuar en base a ellos. De manera semejante, se han desarrollado aplicaciones que emulan el comportamiento humano mediante sistemas computacionales.

A lo largo de la historia se ha podido observar que estas aplicaciones con cierto grado de inteligencia ayudan al ser humano en los procesos disminuyendo el porcentaje de error dentro de estos mismos procesos.

La medicina es uno de los campos del conocimiento que más podrían beneficiarse de una interacción cercana con la computación y las matemáticas, mediante la cual se optimizarían procesos complejos e imperfectos como el diagnóstico diferencial. De esto se ocupa el aprendizaje automático, rama de la inteligencia artificial que construye y estudia sistemas capaces de aprender a partir de un conjunto de datos de adiestramiento y de mejorar procesos de clasificación y predicción.

La neumonía es un tipo de infección respiratoria aguda que afecta a los pulmones. Estos están formados por pequeños sacos, llamados alvéolos, que en las personas saludables se llenan de aire al respirar. Los alvéolos de los enfermos de neumonía están llenos de pus y líquido, lo que hace dolorosa la respiración y limita la absorción de oxígeno.

Según información de la Organización Mundial de la Salud, la neumonía es la principal causa individual de mortalidad infantil en todo el mundo. Se calcula que la neumonía ha matado al menos a 920136 niños menores de 5 años en 2015, lo que supuso el 15% de todas las defunciones de niños menores de 5 años en todo el mundo.

La neumonía afecta a niños y a sus familias de todo el mundo.

En Bolivia entre los años 2018 y 2019, según los responsables del control epidemiológico del Servicio Departamental de Salud, SEDES, se registró un incremento del 66% en casos de neumonías entre menores de cinco años afirmando también que esta es una de las principales causas de mortalidad infantil en Bolivia.

## DESARROLLO

En base a las entrevistas y reuniones que se tuvieron con personal médico, se pudieron determinar requerimientos funcionales importantes, que se reportan en la tabla 1, que tendrían que ser cumplidas por la aplicación:

Tabla 1. Descripción de los Requerimientos Funcionales

Requerimiento Funcional 1	Seleccionar la imagen a evaluar
	Verificar nombre del paciente
Requerimiento Funcional 2	Investigar los parámetros de validación
	Establecer parámetros para la validación
	Realizar testeo de la validación
Requerimiento Funcional 3	Investigar sobre algoritmos de procesamiento
	Aplicar procedimiento de imágenes
	Testear los resultados del procesamiento
	Analizar los resultados del proceso
Requerimiento Funcional 4	Evaluar los resultados
	Emitir un criterio
	Revisar el criterio emitido

Para seleccionar el aprendizaje de la red neuronal se deben identificar y seleccionar los patrones de análisis. En este caso, una enfermedad pulmonar que sólo se identifica y manifiesta en el tórax del paciente, por ende, la zona de interés será el tórax del paciente. Se establece un patrón de colores: El color base será el 6E6D6D y la herramienta tomará este color como referencia para los colores más oscuros de la plaqueta mientras que para los colores claros se tomará el E1DCDC.

Utilizando los métodos estadísticos en el estudio realizado por UC SAN DIEGO HEALTH España (HEALTH, 2020) se determinó que: para lograr 97,9 % de precisión de la red neuronal se necesita almacenar y entrenar con 860 radiografías de tórax. Por lo tanto, conociendo el volumen de datos, se selecciona cual va a ser información y cuál se va a descartar del dataset.

Se definen cuáles serán los datos de entrada o las restricciones que tendrá el sistema de radiología actual ya que la red neuronal será un módulo de este mismo. Entonces, en base a las especificaciones técnicas del modelo que se maneja, se tiene lo siguiente:

Manejo de imágenes JPG o DICOM.

Página elaborada con herramientas Web.

Manejo del sistema en computadora y dispositivos móviles.

Relación con otros sistemas mediante VPN.

Para el filtrado correcto de las imágenes se definen los parámetros para la entrada de datos:

Posición vertical de la imagen: Este parámetro se establece debido a que el análisis de la red neuronal será diferente si la imagen se pasa horizontal o verticalmente, pudiendo generar problemas en la evaluación (Match, 2001).

Dimensión de las imágenes: Se toma como referencia la información de salida del sistema actual, es decir, imágenes con una dimensión de 3000 pixeles de ancho y 4000 de alto con una resolución de 72 dpi.

Peso de las imágenes: Las imágenes tendrán un peso de 2.49 MB.

El diagrama de capas se diseña en base a criterios de evaluación de información. Match, 2001, indica que, de acuerdo a la capa

de entrada, se pueden seleccionar la cantidad de capas ocultas, teniendo dos tipos de entrada para la red neuronal y 3 capas ocultas para tener mayor precisión en la respuesta de salida.

Para evaluar si el modelo resuelve problemas con la estructura planteada se testea el modelo usando playground Tensorflow, debido a la flexibilidad y comodidad para adecuarse a páginas web y por la escalabilidad y gran soporte que posee. Además, se plantea una estructura y se prueba usando una estructura de clasificación y otra de regresión lineal.

Se selecciona un tipo de aprendizaje supervisado, ya que se pasan directamente las imágenes ya filtradas a la red neuronal y ésta sólo tiene que encontrar patrones de aprendizaje.

Se usan dos funciones de activación: La función relu, que muestra los resultados en formato numérico y la función Softmax, que muestra los resultados en porcentaje.

Para visualizar los resultados de la red neuronal y dotarla de una interfaz al usuario se utiliza un entorno web.

Para la simulación de la página web en un servidor se utiliza el entorno web de Anaconda que permite crear múltiples máquinas virtuales y una interfaz didáctica a la hora de instalar las librerías y dependencias de Tensorflow.

El set de datos se pre procesa antes de entrenar la red. Al inspeccionar la primera imagen en el set de entrenamiento, se encuentra que los valores de los pixeles están entre 0 y 255.

Se tienen que escalar los valores en un rango de 0 a 1 antes de alimentarlos al modelo de la red neuronal. Para hacerlo, se dividen los valores entre 255.

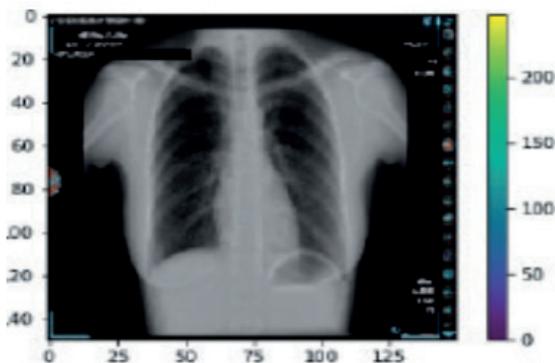


Figura 1. Valores de los pixeles de la imagen.

Construir la red neuronal requiere configurar los filtros, las capas de clasificación del modelo y luego compilar el modelo.

Antes de pasar los datos a las capas de clasificación de la red neuronal, se necesitan aplicar una serie de filtros que ayudarán a la red neuronal a identificar el objeto que se clasifica. Se aplican dos filtros, el primero le permite a la red ir identificando los colores opacos y los colores claros; el segundo filtro permite identificar las líneas que se encuentra en la imagen; el tercer filtro reconoce las figuras que tenga la imagen. La aplicación de filtros se logra con Tensorflow, dando como resultado una imagen con valores que permite al modelo reconocer objetos.

Una vez aplicadas las convoluciones se tiene una red neuronal sólida. Las capas ocultas para el procesamiento permiten

procesar los datos adquiridos por los filtros. Para este problema se usa 1 capa oculta con 3 neuronas,

Para entrenar el modelo se agregan configuraciones durante el paso de compilación del modelo:

Loss function: De acuerdo con las pruebas realizadas en el Playground se toma un valor de 0,004.

Optimizer: Para el optimizador del dataset se toma en cuenta la función Adam de Tensorflow y también se dan 100 épocas para evitar pérdida de información.

Metrics: Para el modelo se usa una métrica de Accuracy que permite realizar testeo y correcciones cada 36 pasos.

Entrenar el modelo de red neuronal se realizan los siguientes pasos:

Se decide tener dos tipos de carpetas, una donde están las fotografías de pacientes con neumonía; otra, donde están los pacientes sanos.

El modelo aprende a asociar imágenes y etiquetas. Las etiquetas son: Neumonía, Sano.

El funcionamiento de la red neuronal convolucional se divide en dos principales procesos:

Aplicación de filtros para reconocer caracteres en la imagen

En este punto la red neuronal aplica los filtros que ya l establecidos para reconocer patrones en la imagen, tomando en cuenta 3 filtros: color, líneas, y formas.

Por cada filtro aplicado empieza a generar un modelo.

Al terminar de aplicar todos los filtros se los une para generar un Stacking, este es el resultado final del primer proceso.

El Stacking pasa a la red neuronal para que ésta pueda comparar los valores del Stacking con los valores del entrenamiento. La red neuronal realiza el cálculo del porcentaje de aproximación que existe en la información de entrada comparada con su información aprendida y 1 o 0 ya que es una red neuronal de selección binaria.

Se seleccionan dos herramientas para el diseño de la interfaz gráfica.

Framework web: Flask, este es un framework de Python que interactúa con modelos de Tensorflow.

Librería de Front-end: Se selecciona flask-bootstrap. Estatiza la página web y brinda una mejor experiencia de usuario.

Para el funcionamiento óptimo de la página web, la documentación de flask toma como referencia la arquitectura planteada en la documentación, modificándola para agregar el modelo de Tensorflow, agregando una carpeta en la cual se guardan las imágenes a evaluar.

Los formularios html se comunican con el modelo de Tensorflow mediante el back-end que proporcione flask.

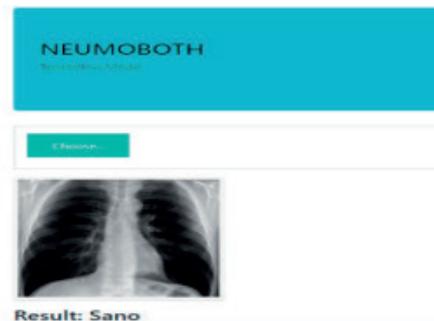


Figura 2. Formulario en físico con todos sus componentes y ejecutando su funcionalidad.

Se realizan 3 tipos de pruebas para demostrar la integridad y validación de los resultados, identificando posibles cuellos de botella.

Es importante el rendimiento del hardware al compilar el modelo. Se usó una Lenovo Ideapad 320 con procesador Intel core i7 7ma generación, con tarjeta de video NVIDIA Geforce 940 MX, pudiendo el CPU procesar 1190 ejemplos por segundo, siendo lo mínimo recomendado 800 ejemplos por segundo.

Para evaluar el rendimiento del modelo se utilizan dos herramientas de Tensorflow. La primera es accuracy que calcula con qué frecuencia las predicciones coinciden con las etiquetas en función de dos variables, total y count. La red neuronal tiene un 98,8% de aciertos. La segunda herramienta es la matriz de confusión que sirve para mostrar de forma explícita cuándo una clase es confundida con otra. Para esta prueba se tomaron 10 imágenes aleatorias del dataset y se procedió a el porcentaje de acierto que existe en la evaluación de cada imagen, tabla 2, tomando datos de la función accuracy y el Stacking que se tiene para la evaluación.

Tabla 2. Porcentaje de aciertos en pruebas unitarias.

Imágenes	Porcentaje de acierto, %	Resultado
1	80	Neumonía
2	85	Sano
3	75	Neumonía
4	88	Neumonía
5	82	Sano
6	83	sano
7	90	sano
8	82	sano
9	85	Neumonía
10	89	Neumonía

Esta evaluación se identifican dos factores muy importantes en el proceso de evaluación.

El porcentaje mínimo de acierto es de un 75% pero, esto también se debe a que el paciente, además, de neumonía posee otra enfermedad pulmonar diferente a la usada en el trabajo. Al verificar los datos de salida se puede ver que el paciente tiene neumonía. Se logra un promedio de aciertos: para pacientes con neumonía 83,4% y para pacientes sanos 84,4%.

Se comparan los resultados de los profesionales en el área con el modelo de la red neuronal. Se tomaron 15 imágenes que no se encuentran en el data set de entrenamiento y que son evaluadas por la red neuronal, se procedió a realizar la misma evaluación con un profesional en el área.

Tabla 3. Pruebas comparativas evaluadas por la red neuronal por profesionales en el área,

Imágenes	Red Neuronal		Doctor	
	Porcentaje de acierto, %	Resultado	Porcentaje de afección, %	Resultado
1	87	Neu	80	Neu
2	90	Neu	88	Neu
3	90	Sn	95	Sn
4	70	Neu	68	Neu
5	72	Sn	68	Sn
6	85	Sn	83	Sn
7	88	Sn	90	Sn
8	78	Sn	82	Sn
9	77	Neu	72	Neu
10	45	Neu	40	Neu
11	85	Sn	82	Sn
12	71	Sn	70	Sn
13	76	Sn	70	Sn
14	87	Sn	82	Sn
15	81	Neu	85	Neu

Neu = Neumonía, Sn = Sano

El proceso actual tiene como tiempo temprano un promedio de 4 días y como tiempo tardío un promedio de 8 días. Con el modelo neuronal el tiempo temprano es de 1 día y el tardío es de 2 días, Esto demuestra una reducción de tiempo del 75% en el diagnóstico de neumonía.

## DISCUSIÓN

Al emplear el uso de las redes neuronales se podrían procesar grandes cantidades de casos clínicos además de ser verificados por personal médico para validar la información, ayudando a reducir los tiempos de diagnóstico.

Mediante los siguientes criterios de evaluación se puede evidenciar la comparación entre el funcionamiento del sistema normal con el sistema con el módulo de red neuronal integrado.

Tabla 4. Criterios de evaluación para evidenciar el funcionamiento del sistema normal con el sistema con el módulo de red neuronal integrado

Criterio de evaluación	Sin el modelo de red neuronal	Con el modelo de red neuronal
Diagnóstico del paciente.	El diagnóstico del paciente puede durar hasta 2 semanas.	El diagnóstico se realiza con la primera radiografía
Accesibilidad de los pacientes	Mediante el sistema de citas.	El acceso para cualquier paciente con radiografías de tórax.
Esfuerzo del especialista	El especialista realiza 100% del trabajo, revisando pacientes con y sin enfermedad	El sistema realizará un 60% el trabajo y el especialista un 40%.
Optimización del proceso de diagnóstico.	El sistema no prioriza pacientes graves	El sistema identifica la gravedad del paciente

En la tabla 5 se describen las ventajas y desventajas para evaluar los problemas que puede tener la aplicación de este sistema a la hora de su implementación y uso.

Tabla 5. Ventajas y desventajas del sistema

Ventajas	Desventajas
Flexibilidad para implementar nuevos módulos.	Se le debe realizar un mantenimiento mensual ya que al trabajar con redes neuronales se tiene una entropía más elevada.
Reducción del tiempo de diagnóstico.	Las fotos que se tomen para la evaluación deben estar validadas y en el formato correcto.
Al ser una página web se logra un mayor alcance de uso de los pacientes.	Se debe realizar una capacitación optima al personal para evitar desconfianza.
Reducción del esfuerzo laboral.	La red neuronal actualmente se encuentra limitada a un tipo de enfermedad.

Dentro de la página web se tienen tres funcionalidades básicas que definen todo el proceso de diagnóstico.

La primera es la funcionalidad de predicción: La red neuronal evalúa la imagen y da un resultado visible al usuario

La segunda es el módulo de la evaluación estadística: Brinda un dato porcentual que le permitiría al médico evidenciar una evaluación más iterativa.

La última funcionalidad es la de reporte: Los resultados de la red neuronal se imprimirían en una hoja para ser validados por el especialista.

La experiencia de usuario dentro de la página web es amigable, ya que la página web solo cuenta con 2 botones que impedirían el usuario se sienta desorientado. Por otro lado, los mensajes de error.

Si se dieran errores del servidor interno u otros se le notifica al usuario y, mediante el Manual de Usuario, solucionar este tipo de situaciones.

## REFERENCIAS

-Carestream Medical. (s.f.). Obtenido de Carestream Medical: <https://www.carestream.com/es/es/medical/products/radiography/carestream-radiography-software/carestream-image-suite-v4>

CLAUDIA, S. (11 de 03 de 2011). Analisis de sistemas. Recuperado el 08 de 04 de 2018, de <http://analisisydisistemas.blogspot.com/2011/03/recopilacion-deinformacion.html>

Company, T. (29 de 11 de 2017). Toyota web-site. Obtenido de <https://observatorio-ia.com/toyota-kirobo-mini-robot-de-compania>

docs.microsoft.com. (s.f.). Obtenido de <https://docs.microsoft.com/en-us/dotnet/csharp/getting-started/introduction-to-the-csharp-language-and-the-net-framework>

Flow, T. (s.f.). Tensor Flow. Obtenido de <https://www.tensorflow.org/tutorials/keras/classification?hl=es>

Gómez, M. d. (2018). Cocomo.

HEALTH, U. S. (27 de 04 de 2020). LabMedica. Obtenido de LabMedica: <https://www.labmedica.es/covid-19/articles/294781999/inteligencia-artificial-permite-el-analisisrapido-de-las-imagenes-de-los-pulmones-en-los-pacientes-con-covid-19.html>

Institute, P. M. (06 de 03 de 2017). PMBOOK V6. En P. M. Institute, PMBOOK V6 (pág. 725). Recuperado el 06 de 03 de 2018, de Maps: <https://www.google.com.bo/maps/>

Kaehler, G. B. (07 de 06 de 2008). Learning OpenCV. En G. B. Kaehler, Learning OpenCV. RepKover. Obtenido de <http://creatividadunity.blogspot.com/2017/06/informacionde-unity.html>

KENDALL, K. Y. (2011). Analisis y Diseño De Sistemas. En K. Y. KENDALL, Analisis y Diseño De Sistemas. Pearson.

Matich, D. J. (2001). Redes Neuronales. En m. J. Matich, Redes Neuronales.

Mconell, S. (1996). Rapid Development. Microsoft Express.

Pressman, R. S. (2002). Ingenieria de Software un enfoque practico. En R. S. Pressman, Ingenieria de Software un enfoque practico. Mexico: mc graw hill.

Romero, J. V. (2010). Radiologia de Torax. En J. V. Romero, Radiologia de Torax.

SEDES, A. E. (2019). Pagina Oficial del sedes. Obtenido de <https://www.minsalud.gob.bo/component/jdownloads/send/5-boletin-20016/341-parte-epidemiologico-ano13-semana-24>

Seram, C. (24 de 09 de 2014). Seram. Obtenido de [https://epos.myesr.org/esr/viewing/index.php?module=viewing\\_poster&task=viewsection&pi=125073&ti=414653&si=1419&searchkey=](https://epos.myesr.org/esr/viewing/index.php?module=viewing_poster&task=viewsection&pi=125073&ti=414653&si=1419&searchkey=)

CITA

