

Identificación de radiografías de tórax patológicas y no patológicas mediante procesamiento digital de imágenes y técnicas de aprendizaje de máquina

Andrés Felipe Muñoz Díaz^a, Hernán Darío Vargas Cardona^b

^a: *Autor del proyecto de investigación*

^b: *Director del proyecto de investigación*

Resumen:

En el mundo, gran cantidad de personas padecen enfermedades respiratorias, las cuales pueden ser o no diagnosticadas. A causa del mal o tardío diagnóstico, se presentan gran cantidad de muertes al año, por lo cual es importante encontrar una manera viable que permita detectar las patologías prematuramente para así mismo poder dar tratamiento oportuno y no en etapas avanzadas de las enfermedades. Dado esto, este trabajo propone una metodología en lenguaje Python la cual permite identificar radiografías de tórax patológicas y no patológicas. Lo anterior se hace a partir de 3 etapas, la primera de pre-procesamiento de imágenes, en la que se realiza una limpieza de las imágenes diagnósticas y eliminación de ruido. La segunda una etapa de extracción de características discriminativas y una tercera etapa donde a partir de técnicas de aprendizaje de máquina para realizar la clasificación propuesta desde diferentes algoritmos como lo son máquinas de soporte vectorial (SVM) o redes neuronales convolucionales (CNN) creadas desde 0 o a partir de transfer learning. Al final del proyecto se podrá evaluar la viabilidad de la inteligencia artificial en el campo médico mediante el análisis de la precisión y pertinencia de los diferentes algoritmos de clasificación para el conjunto de datos utilizado en el proyecto.

Introducción:

Las enfermedades respiratorias son consideradas como una de las principales

causas de muerte y discapacidad en el mundo, debido a la vulnerabilidad de los pulmones causada por las partículas, químicos, infecciones e impurezas en el aire. Aunque el deterioro respiratorio se genera en todas las regiones del mundo y en todas las clases sociales, la pobreza, el hacinamiento, las exposiciones ambientales y las malas condiciones de vida aumentan la vulnerabilidad de estos trastornos. Además, las enfermedades respiratorias causan el 10 % de todos los años de vida perdidos ajustados por discapacidad (AVAD) [1].

Con el fin de diagnosticar y tratar oportunamente las enfermedades es necesario utilizar herramientas o tecnologías como la inteligencia artificial (IA), la cual es una rama de la computación capaz de analizar conjuntos de datos médicos complejos [2]. Los métodos de IA se han convertido en una herramienta popular para los investigadores médicos, dado que estas técnicas pueden descubrir e identificar patrones [3], ayudando a predecir si un paciente tiene o no una enfermedad.

Debido a las elevadas cifras de personas que padecen enfermedades respiratorias en el mundo, diagnosticadas o no diagnosticadas y a la cantidad de muertes al año, es importante encontrar una manera efectiva, económica, fácil y rápida que permita detectar las patologías prematuramente para así mismo poder dar tratamiento oportuno y no en etapas avanzadas de las enfermedades. Dado esto, en el desarrollo de este proyecto se usaron

técnicas de inteligencia artificial para dar una solución que cumpla con lo descrito anteriormente y que permita identificar pacientes enfermos y no enfermos a partir del análisis de radiografías de tórax.

Objetivos general

Aplicación de una metodología para la identificación de radiografías de tórax patológicas y no patológicas mediante procesamiento digital de imágenes y técnicas de aprendizaje de máquina.

Objetivos específicos

- Implementar una etapa de pre-procesamiento de las radiografías digitales que incluye filtrado, eliminación de artefactos y segmentación de la región de interés.
- Desarrollar una fase de extracción de características discriminativas de las radiografías a partir de descriptores geométricos, estadísticos, de textura y técnicas basadas en transformadas.
- Identificar radiografías patológicas y no patológicas empleando técnicas de aprendizaje de máquina

Fundamentación teórica

Inteligencia Artificial: La Inteligencia Artificial (IA) es un término general que implica el uso de una computadora para modelar y/o replicar el comportamiento inteligente. La investigación en IA se centra en el desarrollo y análisis de algoritmos que aprenden y/o realizan un comportamiento inteligente con una mínima intervención humana [4].

Machine Learning: El machine learning o aprendizaje automático es una rama de la inteligencia artificial que tiene como objetivo enseñar a las computadoras cómo aprender y actuar sin ser programadas explícitamente. Más específicamente, el aprendizaje

automático es un enfoque para el análisis de datos que implica construir y adaptar modelos, que permiten a los programas “aprender” a través de un entrenamiento [5].

Máquina de Soporte Vectorial (SVM): Las máquinas de soporte vectorial son algoritmos supervisados de aprendizaje automático utilizados para clasificación, regresión y detección de valores atípicos. Las SVM son efectivas en espacios con alta dimensionalidad e inclusive cuando se cuenta con más atributos que datos, presentando un alto dinamismo y adaptabilidad a los problemas por los diferentes kernel con los que se puede utilizar [6].

Deep Learning: El Deep learning es un subconjunto del aprendizaje automático donde las redes neuronales artificiales, algoritmos inspirados en el cerebro humano, aprenden de grandes cantidades de datos. De manera similar a cómo aprendemos de la experiencia, el algoritmo de deep learning realizaría una tarea repetidamente, donde cada vez aprende más del resultado[7].

Red Neuronal Convolutiva (CNN): Una red neuronal convolutiva, es un algoritmo supervisado de deep learning el cual realiza el aprendizaje directamente de los datos sin necesidad de proporcionar características manualmente. Las CNN son utilizadas en reconocimiento y clasificación de imágenes, audio, series de tiempo y señales[8]. La ventaja de las CNN es que son altamente precisas, extrae características de los datos y puede ser reutilizada para otros problemas, pero tiene el limitante que puede requerir alto consumo de recursos de hardware[8].

Extracción de Características: La extracción de características es un proceso en el cual un conjunto inicial de datos sin procesar se reduce a grupos más manejables para el procesamiento. Un conjunto grande

conjuntos de datos es aquel que cuenta con una gran cantidad de variables y requieren elevados recursos de máquina para ser procesados. La extracción de características es el nombre de los métodos que seleccionan y/o combinan variables en características, reduciendo efectivamente la cantidad de datos que deben procesarse, mientras que aún describen de manera precisa y completa el conjunto de datos original [9].

Transfer Learning: Transfer learning es un método de Deep Learning, el cual a utiliza un modelo previamente existente y lo entrena nuevamente para un problema nuevo relacionado con el original. Hay numerosas aplicaciones en las que resaltan transferencia de características o del balanceo de los nodos, en las cuales se mantienen ciertas capas de la red y se entrenan nuevamente las otras. [10].

Desarrollo y resultados

Lo primero que se hizo fue se seleccionar el conjunto de datos, el cual consistió en hacer un barrido aleatorio por los datos dentro de estas y se seleccionó la proveniente del NIH Clinical Center de Estados Unidos pues a consideración del autor es muy completa y las imágenes son mayormente uniformes y de buena calidad. La base de datos consistía de carpetas con 45000 radiografías de tórax y un archivo de excel con nueve columnas de información de los datos y la clasificación de los mismos. Finalmente para adecuar las imágenes con las que se contaban, se depuró dejando solamente las radiografías frontales y se ajustó el Excel para solo tener el nombre del archivo y si era o no de una persona enferma. Al finalizar la selección y depuración de las imágenes del proyecto, se contó con un conjunto de datos balanceado el cual contiene 5190 imágenes de las cuales 2550 pertenecían a personas sanas y 2640 a radiografías patológicas.

Primero y como parte del pre-procesamiento de las imágenes del conjunto de datos, se buscó reducir el ruido a partir de la transformada wavelet utilizando la función Daubechies. Se utilizó la descomposición ortogonal wavelet de nivel dos y posteriormente a este, se realizó un proceso de umbralización (thresholding) de los coeficientes de la imagen descompuesta, mediante el método de umbralización por reducción Bayesiana y posterior mente se utilizó la transformada inversa wavelet. Posterior a esto se utilizó el algoritmo CLAHE sobre las imágenes y se redujo la dimensionalidad mediante interpolación proximal dejando como resultados imágenes de 200 x 200.

Para la extracción manual de características, se buscó cuáles eran utilizadas a menudo y cuáles técnicas se aplican para la extracción de las mismas. Lo primero que se hizo, fue la implementación de un patrón binario local(LBP) para luego con estas sacar las primeras dos características las cuales eran la energía y la entropía de Shannon. Luego se implementó la matriz de coeficientes de escalas de grises (GLCM) esto se hizo en 4 ángulos 0° , 90° , 180° y 270° sacando para cada ángulo 5 características de textura que fueron las cuales fueron contraste, disimilitud, homogeneidad, energía y correlación. Como últimas dos características se extrajo nuevamente la energía y la entropía pero esta vez a partir de un filtro Gabor que se implementó en cada una de las imágenes. Finalmente se normaliza la matriz de características y se remueven las características cuya varianza sea menor a 0,001 para evitar valores que no aporten en el aprendizaje del modelo. El proceso descrito se presenta en la siguiente imagen.

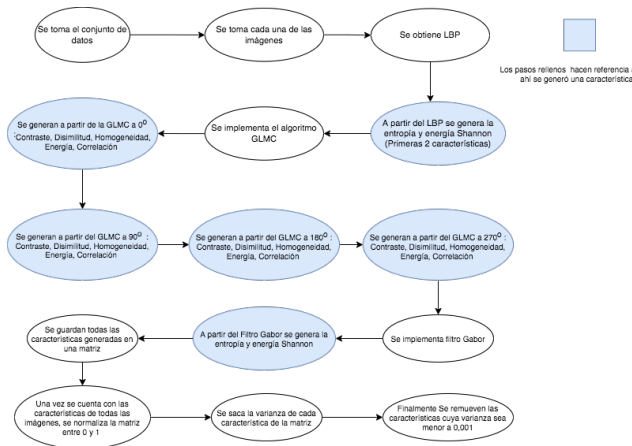


Figura 1: Diagrama del proceso de extracción de características

Cómo segunda alternativa a la extracción de características, se utilizó transfer learning para a partir del modelo VGG19 generar un extractor de características por las cuales se pasaron cada una de las imágenes.

Una vez se tenía la etapa de extracción de características, se desarrollaron varios modelos de aprendizaje de máquina para evaluar el desempeño y ver cual entregaba mejores resultados. Lo primero que se implemento fue una SVM con kernel lineal, luego una SVM con kernel RBF luego de esto, se hizo validación cruzada para identificar que combinación de valores debían tener los hiperparámetros para ver cuales entregaban mejores resultados. Luego de la ejecución con las características extraídas manualmente, se identificó que para la SVM de kernel lineal los mejores resultados provenían de $C=0.1$ que presentaba una precisión del 73% y en el caso del kernel RBF provenían de $C=6$ y $\gamma=10$ y $C=10$ y $\gamma=6$ dando para ambas combinaciones un 76% de precisión. Para el caso de las características provenientes del extractor de características por transfer learning todos las imágenes fueron calificadas como personas enfermas es decir que quedó sesgado.

Luego, se implementó una CNN desde 0 y se pasó por esta toda la base de datos de imágenes, y se ejecutó 10 ciclos de entrenamiento y validación dando como resultado una precisión promedio de 80,193% y una desviación estándar del 2,63%. Finalmente, como ultimo método se utilizo la red VGG19 mediante transfer learning, se mantuvo sus datos de entrenamiento en todas las capas menos en la final que fue entrenada y validada con todo el conjunto de datos del proyecto, el cual luego de 10 iteraciones entregó una precisión del 83.028% y una desviación estándar de 5.36%.

Discusión y conclusiones

Con las altas cifras de pacientes que fallecen en el mundo y en especial en países con escasos recursos por malos o tardíos diagnósticos de las enfermedades se concluye que la implementación de este tipo de tecnologías y utilización en hospitales podrían ayudar a salvar muchas vidas mediante tratamientos en etapas tempranas de las patologías. Como conclusión principal se identificó que es viable y pertinente la utilización de un modelo de aprendizaje de máquina como mecanismo de apoyo médico detectar patologías en el sistema respiratorio. En este proyecto se destacó el uso de Deep Learning con Transfer learning a partir del modelo pre-entrenado VGG19, el cual tuvo una precisión promedio de 83,028% en la validación realizada, la cual es una cifra prometedora en un proyecto exploratorio como este.

Para futuros trabajos o ampliaciones de esta investigación, se recomienda en la manera de lo posible incrementar la cantidad de imágenes del conjunto de datos, incluyendo de esta manera otros tipos de enfermedades. Así se podrían obtener mejores resultados y no solamente detectar si la persona está

enferma o no, sino también que pueda decir cual es la enfermedad que padece. Además, se recomienda contar con equipos que tengan recursos de Hardware (RAM y GPU) elevados para agilizar el proceso de entrenamiento y validación del modelo, pues a mayor cantidad de datos y complejidad del modelo, mayor el procesamiento que se requiere. Se recomienda utilizar inteligencia artificial en investigaciones en el campo médico que no solamente se relacionen con el sistema respiratorio o radiografías de tórax sino también a otro tipo de exámenes u órganos del cuerpo.

Bibliografía:

- [1] World Health Organization. Global Alliance against Chronic Respiratory Diseases. https://www.who.int/gard/news_events/1-3.GARD-06-07-K1.pdf, 2000
- [2] J. R. T. Monson P. J. Drew A. N. Ramesh, C. Kambhampati. Artificial intelligence in medicine. Annals of the Royal College of Surgeons of England, 2004.
- [3] Konstantinos P. Exarchos Michalis V. Karamouzis Dimitrios I. Fotiadis Konstantina Kou-rou, Themis P. Exarchos. Machine learning applications in cancer prognosis and prediction. Computational and Structural Biotechnology Journal, 2015.
- [4] College of Science Engineering. Robotics and Artificial Intelligence. University of Minnesota
- [5] Apife D'arcy John D. Kelleher, Brian Mac Namee. Fundamentals of Machine Learning for predictive data analytics. MIT Press, 2015
- [6] Gandhi R. Support Vector Machine - Introduction to machine Learning Algorithms. Towards Data Science, 2016
- [7] Bernard Marr. What Is Deep Learning AI? A Simple Guide With 8 Practical Examples. Forbes, 2018
- [8] Inc The MathWorks. Redes Neuronales Convolucionales 3 cosas que necesitas saber. The Math- Works, Inc: <https://la.mathworks.com/discovery/convolutional-neural-network-matlab.html>
- [9] Massoud Nikravesh Lofty Zadeh Isabelle Guyon, Steve Gunn. Feature Extraction Foundations and Applications. Springer, Studies in Fuzziness and Soft Computing vol 207, 2006
- [10] Jones T. Clinical Center - Mission. NIH: <https://www.nih.gov/about-nih/what-we-do/nih-almanac/clinical-center-cc>, 2018