

RSL Sobre Diagnóstico de COVID-19 Utilizando Redes Neuronales Artificiales Convolucionales

Eduardo Hugo Bennesch¹, Rocio Klan², Juan Claudio Mousquere³
Postgrado, Facultad de Ciencias Exactas, Químicas y Naturales, Universidad Nacional de Misiones
Posadas, Misiones, República Argentina.

1 Ingennesch@gmail.com, 2 Rocioklan@gmail.com, 3 J.C.Mousquere@gmail.com

Resumen. La rápida propagación del COVID-19 a nivel mundial obligó a desarrollar sistemas y métodos para predecir el comportamiento del virus o detectar la infección. Una de las formas de detectar al COVID-19 es a través del análisis de Rayos X o de Tomografías Computarizadas del tórax, por lo que resulta relevante desarrollar modelos de IA que puedan asistir en la toma de decisiones. El objetivo de este informe es presentar una Revisión Sistemática de la Literatura (RSL) para evidenciar los avances en el desarrollo de soluciones software utilizando Redes Neuronales Artificiales (RNA) enfocadas en la detección del COVID-19. La búsqueda de artículos se realizó en seis fuentes diferentes. Como resultado, se obtuvieron 18 estudios clasificados en 5 dimensiones: Tipos de Propuestas, Tipos de datos, Validación, Características y Tipo de Soporte. Este trabajo evidencia que existen en simultáneo una gran cantidad de investigaciones relacionadas, que apuntan a la necesidad de encontrar soluciones prácticas, de bajo costo y de rápida evolución. La mayoría de los trabajos estudiados hacen hincapié en el dinamismo de los métodos de entrenamiento y la precisión de las respuestas.

Palabras Clave: redes neuronales convolucionales, machine learning, detección por imágenes, COVID-19, diagnóstico temprano.

1 Introducción

El diagnóstico precoz de COVID-19 permite a los profesionales de la salud conjuntamente con las autoridades gubernamentales romper la cadena de transmisión y aplanar la curva epidémica [1]. En marzo de 2020, el crecimiento de casos de COVID-19 escaló a aproximadamente 35000 diagnósticos en solo 15 días en todo el mundo [2].

El COVID-19 causa, desde síntomas leves a casos de estados graves o críticos [3]. El número total de casos de COVID-19 al momento de realizar la RSL es de aproximadamente 336.068, de los cuales 223.819 se consideran activos y 112.249 son catalogados como casos cerrados.

De los casos activos, el 95% de los pacientes, es decir 213.179 personas presentan síntomas leves y el 5% restante es, decir: 10.640 presentan cuadros severos o críticos.

Mientras que el 87% de los casos cerrados, en otras palabras, 97.636 personas se recuperaron y el 13%, 14.613 personas, fallecieron.

Las Redes Neuronales Convolucionales también conocidas como RNC o CNN por sus siglas en inglés [4] representan una técnica de aprendizaje profundo que consta de varias capas apiladas juntas que utilizan conexiones locales conocidas como campo receptivo local y distribución de peso para un mejor rendimiento y eficiencia. La arquitectura profunda ayuda a estas redes a obtener muchas características diferentes y complejas que una red neuronal simple no puede aprender. Las RNC han demostrado un excelente rendimiento en varias aplicaciones, como la clasificación de imágenes, detección de objetos, reconocimiento de voz, procesamiento del lenguaje natural y análisis de imágenes médicas. En la **Imagen 1** se puede observar la visión general de esta metodología.

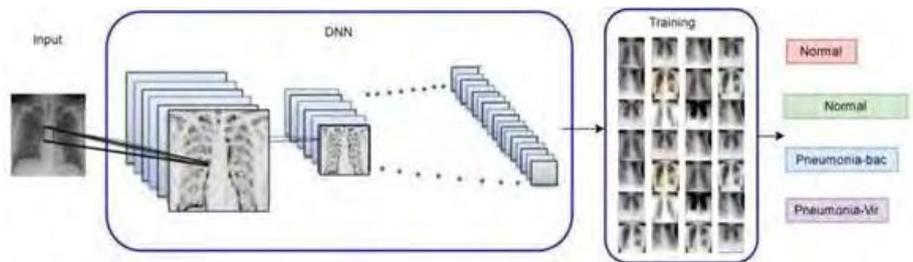


Imagen 1: Funcionamiento de una RNC [5].

El presente trabajo está organizado de la siguiente manera, en la sección 2 son presentadas las características de la RSL, objetivos, preguntas de investigación, cadenas de búsqueda y criterios de inclusión y exclusión. La sección 3 contiene la ejecución de la RSL. La sección 4 se presenta el reporte de resultados obtenidos y finalmente, en la sección 5 se muestran las conclusiones y futuras líneas de trabajo.

Trabajos Relacionados. Mediante el trabajo de investigación ejecutado, podemos afirmar que al momento de la realización del mismo no existe ninguna RSL realizada sobre el tema elegido.

2 Planificación de la RSL

El objetivo de esta etapa es definir el protocolo de la revisión. Para ello serán elaborados el objetivo de la revisión, las preguntas de investigación que se pretenden responder con esta revisión, la cadena de búsqueda, las fuentes donde se realizarán las búsquedas, los criterios de inclusión y exclusión de artículos y las dimensiones a utilizar para clasificar los estudios primarios obtenidos.

2.1 Objetivos y Preguntas de Investigación

2.1.1 Objetivos

Esta RSL se realiza con el objetivo de *sintetizar* la literatura existente acerca del Diagnóstico de COVID-19 Utilizando Redes Neuronales Artificiales Convolucionales. El conocimiento extraído de esta RSL será la base para un mejor entendimiento de los adelantos científicos en materia de investigación acerca de la utilización del Diagnóstico por Imágenes en la detección temprana de síntomas compatibles con COVID-19.

2.1.2 Preguntas de Investigación

- ¿Qué tipo de Metodologías existen para detectar COVID-19 con RNC?
- ¿Cómo fue el tratamiento de los orígenes de datos?
- ¿Cómo puede ayudar las RNC a mejorar la velocidad de detección de casos de COVI- 19?
- ¿Cuáles son las ventajas de las redes neuronales convolucionales sobre otras redes neuronales en el manejo de imágenes?
- ¿Existen formas de automatizar los resultados?
- ¿Cómo se validan las metodologías?

A continuación, en la **Tabla 1** se detallan las preguntas realizadas y las dimensiones correspondientes a cada pregunta.

Tabla 1: Preguntas y dimensiones.

Preguntas	Dimensiones
¿Qué tipo de Metodologías existen para detectar COVID-19 con RNC?	Tipos de Propuestas: método, conocimiento, herramienta, características.
¿Cómo fue el tratamiento de los orígenes de datos?	Tipo de datos.
¿Cómo puede ayudar las RNC a mejorar la velocidad de detección de casos de COVID-19?	Validación: propuesta, ejemplo, conclusión.
¿Cuáles son las ventajas de las redes neuronales convolucionales sobre otras redes neuronales en el manejo de imágenes?	Característica: definiciones.
¿Existen formas de automatizar los resultados?	Tipo de Soporte: manual, herramienta.
¿Cómo se validan las metodologías?	Validación

2.2 Cadena de Búsqueda

En la **Tabla 2** se enumeran las palabras clave y las relacionadas seleccionadas, para conformar la cadena de búsqueda.

Tabla 2: Palabras clave y relacionadas

Palabras Clave	Palabras Relacionadas
covid-19	Coronavirus, nova covid-19
Convolutional	
neural	
Network	

Utilizando los operadores lógicos AND y OR se obtuvo la siguiente cadena de búsqueda:

“(covid-19 OR nova covid-19 OR coronavirus) AND (convolutional) AND (neural) AND (network)”

2.3 Fuentes de Búsqueda

Las búsquedas fueron realizadas en los siguientes repositorios digitales:

- <https://scholar.google.es>
- <https://www.sciencedirect.com>
- <https://ieeexplore.ieee.org/Xplore/home.jsp>
- <http://dl.acm.org/>
- <http://www.biblioteca.mincyt.gob.ar/recursos/ver?id=scielo>
- <https://www.elsevier.com/solutions/scopus>

2.4 Criterios de Exclusión e Inclusión

Criterio de exclusión:

- Fecha de publicación del artículo, fue omitido todo lo anterior a la fecha de aparición del “paciente cero” de la enfermedad.

Criterios de Inclusión:

- Artículos sobre diagnóstico de COVID-19 utilizando redes neuronales.
- Diagnóstico automatizado de COVID-19.
- Aplicación de técnicas de Deep Learning en la detección de COVID-19.

3 Ejecución de la RSL

- Se realizó la búsqueda según la cadena de búsqueda en el título (artículos encontrados), teniendo en cuenta las facilidades que proporciona cada fuente, para filtrar los artículos.
- Se filtraron los artículos de acuerdo al título y al abstract.
- Se obtuvieron estudios primarios leyendo el texto completo.
- Se clasificaron los estudios primarios según las dimensiones definidas.

En la **Tabla 3** se presenta una descripción cuantitativa de los resultados, donde se indica para cada fuente, la cantidad de artículos encontrados, los artículos restantes luego de leer el título y el abstract, y finalmente, los artículos obtenidos luego de leer el texto completo. También se observa la gran cantidad de resultados en bruto en el google académico, debido a la carencia de filtros más específicos que si brindan las otras fuentes de búsqueda.

Tabla 3: Síntesis de las búsquedas.

Fuente	Artículos encontrados	Después del primer filtrado	Después del texto completo
Science Direct	20	3	3
Google Académico	1.290	15	13
ACM	0	0	0
MINCYT	0	0	0
IEEE	7	0	0
SCOPUS	0	0	0
Totales	1.317	18	16

4 Reporte de Resultados

4.1 ¿Qué tipo de Metodologías existen para detectar COVID-19 con RNC?

4.1.1 Redes Neuronales Concatenadas

En el estudio [6] se entrenaron redes ResNet50V2, Xception y una concatenación de redes neuronales Xception y ResNet50V2 utilizando la biblioteca Keras.

La red neuronal concatenada está diseñada concatenando las características extraídas de Xception y ResNet50V2 y luego conectando las características concatenadas a una capa convolucional que está conectada al clasificador. Esta red neuronal ha mostrado una mayor precisión en comparación con las demás.

4.1.2 CoroNet

En la investigación [1] se implementó CoroNet que es una arquitectura RNC diseñada para la detección de infección por Covid-19 a partir de imágenes de rayos X de tórax. Se basa en la arquitectura Xception RNC. Xception, que significa la versión Extreme de Inception (su modelo predecesor) es una arquitectura RNC de 71 capas de profundidad previamente entrenada en el conjunto de datos ImageNet. Xception utiliza capas de convolución separables en profundidad con conexiones residuales en lugar de convoluciones clásicas.

4.1.3 Deep Feature Extraction

En [7] se usó un modo de sintonización superficial durante la adaptación y el entrenamiento de un modelo RNC pre-entrenado de ImageNet usando el conjunto de datos de imágenes de rayos X de tórax recopilados. Se utilizaron las características de RNC disponibles en el mercado de modelos pre-entrenados en ImageNet (donde el entrenamiento se realiza solo en la capa de clasificación final) para construir el espacio de características de la imagen.

Sin embargo, debido a la alta dimensionalidad asociada con las imágenes, se aplicó en [7] Análisis de Componentes Principales (por sus siglas en inglés PCA) para proyectar el espacio de características de alta dimensión en una dimensión inferior, donde se ignoraron las características altamente correlacionadas. Este paso es importante para que la descomposición de la clase produzca clases más homogéneas, reduzca los requisitos de memoria y mejore la eficiencia del marco.

4.1.4 Arquitectura DeTraC

El modelo DeTraC consta de tres fases. En la primera fase, se entrenó el modelo RNC pre-entrenado de backbone de DeTraC para extraer características locales profundas de cada imagen. Luego se aplicó la capa de descomposición de clase de DeTraC para simplificar la estructura local de la distribución de datos. En la segunda fase, el entrenamiento se lleva a cabo utilizando un sofisticado método de optimización de descenso de gradiente. Finalmente, se usó la capa de composición de clase de DeTraC para refinar la clasificación final de las imágenes. Los componentes de descomposición de clase y composición se agregan respectivamente antes y después de la transformación del conocimiento de un modelo RNC pre-entrenado de ImageNet. El componente de descomposición de clase que apunta a dividir cada clase dentro del conjunto de datos de imagen en k subclases, donde cada subclase se trata de forma independiente. Luego, esas subclases se ensamblan nuevamente utilizando el componente de composición de clase para producir la clasificación final del conjunto de datos de imagen original [7].

4.1.5 SegNet

En [8] se presentó una red unificada de alta precisión para la segmentación de la infección por COVID-19 a partir de imágenes de TC de tórax. Esta red consta de dos partes: codificador y decodificador. El codificador con 4 capas (es decir, E1, E2, E3, E4) obtiene información sólida a través del extractor de características y PASPP (Pooling Progresivo de la Pirámide Espacial de Atrous). Cada capa emplea bloques residuales y FV (Feature Variation) como operaciones básicas para extractores de características, excepto la capa E4. El bloque residual suma las características de entrada y los resultados después de dos capas convolucionales, lo que alivia efectivamente el gradiente de fuga.

4.1.6 Enfoque de Aprendizaje Desequilibrado

En [9] se utilizó un conjunto de datos altamente desequilibrado, lo que podría conducir a un aprendizaje sesgado del modelo, sin embargo, el número de imágenes de CXR infectadas con coronavirus es muy inferior en comparación con otras clases, por lo tanto, las técnicas de equilibrio de clase deben asegurarse para suavizar el proceso de aprendizaje. En este trabajo se discuten dos enfoques para manejar el problema de desequilibrio de clase: enfoque de clase de peso y sobre-muestreo aleatorio.

4.1.7 Redes Neuronales Convolucionales Basadas en la Evolución Diferencial Multiobjetivo

En [10] se plantea la utilización de redes neuronales convolucionales basadas en la evolución multiobjetivo-diferencial (MODE) para la clasificación de pacientes infectados por COVID-19 a partir de imágenes de TAC del tórax. El trabajo refleja la buena performance que propone el modelo y hace referencia al problema que presenta en los ajustes de hiperparámetros.

En la **Imagen 2** se muestra el funcionamiento del proceso de entrenamiento y testing de éste modelo de clasificación.

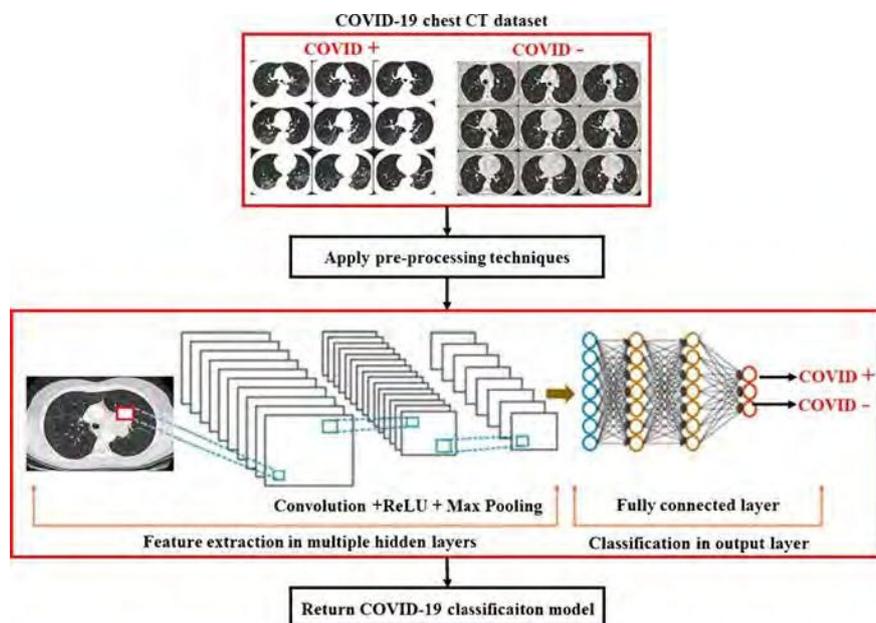


Imagen 2: Diagrama de bloques del proceso de entrenamiento del modelo de clasificación COVID-19 basado en la CNN [10].

4.2 ¿Cómo pueden ayudar las RNC a mejorar la velocidad de detección de casos de COVID-19?

- **Triaje rápido:** Una CXR (Radiografía de Tórax) permite el triaje rápido de pacientes con sospecha de COVID-19 y se puede hacer en paralelo a las pruebas virales (lo que lleva tiempo) para ayudar a aliviar los altos volúmenes de pacientes, especialmente en las áreas más afectadas donde se han quedado sin capacidad (por ejemplo, Nueva York, España e Italia), o incluso de forma independiente cuando las pruebas virales no son una opción (bajo suministro). Además, la CXR puede ser bastante efectiva para el triaje en áreas geográficas donde se les indica a los pacientes que se queden en casa hasta la aparición de síntomas avanzados (p. Ej., La ciudad de Nueva York), ya que a menudo se ven anomalías en el momento de la presentación cuando llegan pacientes con sospecha de COVID-19 en sitios clínicos [11].
- **Disponibilidad y accesibilidad:** Las CXR están fácilmente disponibles y accesibles en muchos sitios clínicos y centros de imágenes, ya que se considera un equipo estándar en la mayoría de los sistemas de atención médica [11].
- **Portabilidad:** la existencia de sistemas CXR portátiles significa que las imágenes se pueden realizar dentro de una sala de aislamiento, lo que reduce significativamente el riesgo de transmisión de COVID-19 durante el transporte a sistemas fijos, como escáneres de TC, así como dentro de las salas que albergan los sistemas de imágenes fijas [11].

- En [9] se puede observar que se logra un alto grado de VPP (Valor de Predicción Positiva) para los casos de COVID-19 (entre 98,4% y 98,9%), lo que indica muy pocas detecciones “falsas positivas de COVID-19”.

4.3 ¿Cómo fue el tratamiento de los orígenes de datos?

En [12] se utilizó un conjunto de datos COVID-CT. Primero se recolectaron 760 preimpresiones sobre COVID-19 de medRxiv1 y bioRxiv2, publicadas del 19 de enero al 25 de marzo. Muchas de estas preimpresiones informan casos de pacientes con COVID-19 y algunas de ellas muestran tomografías computarizadas en los informes. Las tomografías computarizadas están asociadas con subtítulos que describen los hallazgos clínicos en las tomografías computarizadas. Para extraer la información de estructura de bajo nivel de los archivos PDF de preimpresiones se utilizó PyMuPDF3.

Si bien COVID-CT es el dataset más grande que existe de CT sobre COVID-19, aun es pequeño. El entrenamiento de modelos de aprendizaje profundo en un conjunto de datos tan pequeño puede conducir fácilmente a un sobreajuste: el modelo funciona bien en los datos de entrenamiento, pero se generaliza mal en los datos de prueba. Para abordar este problema, se adoptaron dos enfoques: aprendizaje de transferencia y aumento de datos. El aprendizaje de transferencia tiene como objetivo aprovechar una gran colección de datos de un dominio relevante para ayudar con el aprendizaje en el dominio interesado [12].

4.3.1 Dataset Annotation

En [8] aunque se capturaron suficientes datos de las imágenes de TC del tórax COVID-19, las etiquetas anotadas precisas también eran indispensables. Para permitir que ese modelo aprenda sobre anotaciones precisas, crearon un equipo de seis anotadores con antecedentes de radiología profunda y habilidades de anotación competentes para anotar las áreas y límites de las regiones de infección pulmonar y COVID-19. Además, la calidad de las anotaciones finales fue evaluada por un radiólogo senior con experiencia clínica de primera línea de COVID-19.

4.4 ¿Cuáles son las ventajas de las Redes Neuronales Convolucionales sobre otras Redes Neuronales en el manejo de imágenes?

En [6] al concatenar las características de salida de ambas redes, ayudamos a la red a aprender a clasificar la imagen de entrada de ambos vectores de características, y esto ha resultado en una mejor precisión respecto de otro tipo de redes. Se logró una precisión promedio de 99.56% y 80.53% de recuperación para la clase COVID-19, y una precisión general igual a 91.4% entre cinco pliegues.

En [5] el modelo CoroNet logró una precisión general de 89.5%, mientras que la precisión y la medida F para la clase Covid-19 son 96.6% y 98% respectivamente.

4.5 ¿Existen formas de automatizar los resultados?

En [3] se propuso una predicción automática de COVID-19 utilizando una red neuronal de convolución profunda basada en modelos de transferencia pre-entrenados e

imágenes de rayos X de tórax. Para ese propósito, utilizaron los modelos pre-entrenados ResNet50, InceptionV3 e Inception-ResNetV2 para obtener una mayor precisión de predicción para pequeños conjuntos de datos de rayos X. En este estudio se confirma que las imágenes de rayos X del tórax son una buena herramienta para la detección de COVID-19. También se ha demostrado que los modelos pre-entrenados producen resultados muy altos en el pequeño conjunto de datos (50 COVID-19 vs. 50 Normal).

En [10] se plantea la clasificación de imágenes de tomografías computadas usando redes neuronales convolucionales basadas en la evolución diferencial multiobjetivo.

En [8] se presentó una red unificada de alta precisión para la segmentación de la infección por COVID-19 a partir de imágenes de TC de tórax. Esta red consta de dos partes: codificador y decodificador

4.6 ¿Cómo se validan las metodologías?

En [13] para comenzar la fase de capacitación de uno de los siete modelos de aprendizaje profundo seleccionados y / o ajustados, el conjunto de datos preprocesado se divide en 80-20 de acuerdo con el principio de Pareto. Eso significa 20% de los datos de la imagen se utilizarán para la fase de prueba. Nuevamente, al dividir el 80% de los datos se usarán para construir un entrenamiento similar además de los conjuntos de validación.

5 Conclusiones

Consideramos que el principal impacto de este trabajo es que permite conocer, de manera sintética, los avances en el campo de la detección de COVID-19 mediante el análisis de imágenes, identificando las técnicas desarrolladas al momento de la realización de esta primera RSL acerca del tema, esperando sirva como punto de partida para futuras investigaciones.

La velocidad en el diagnóstico es crítica, por tal motivo se evidenció la existencia en simultáneo de trabajos relacionados entre sí, buscando soluciones *rápidas y eficaces*. La sugerencia automatizada de un diagnóstico de COVID-19 aplicando RNC para el análisis de tomografías computadas de pecho, aporta una opción con muy buena precisión al profesional de la salud.

Los resultados obtenidos demuestran que el soporte a las unidades médicas a través de la aplicación de redes neuronales convolucionales para la detección temprana de los síntomas agilizan los diagnósticos permitiendo salvar vidas.

El diseño e implementación de arquitecturas de redes neuronales convolucionales en el tratamiento de imágenes para la detección de COVID-19 aportan mejoras en tiempos de entrenamiento de la RNC, precisión en los resultados y mejoras en la utilización de los datasets permitiendo conjuntos de datos pequeños (Menos de 80 imágenes) sin alterar la precisión. Por tal motivo limitamos la investigación al campo de la aplicación de las RNC.

Como trabajo futuro proponemos investigar otras técnicas de análisis de imágenes para la identificación de síntomas de COVID-19.

Referencias

- [1] P. Afshar, S. Heidarian, F. Naderkhani, A. Oikonomou, K. N. Plataniotis, and A. Mohammadi, "COVID-CAPS: A Capsule Network-based Framework for Identification of COVID-19 cases from X-ray Images," Apr. 2020, Accessed: May 01, 2020. [Online]. Available: <http://arxiv.org/abs/2004.02696>.
- [2] "geographical-distribution-2019-ncov-cases." <https://www.ecdc.europa.eu/en/geographical-distribution-2019-ncov-cases> (accessed May 01, 2020).
- [3] A. Narin, C. Kaya, and Z. Pamuk, "Automatic Detection of Coronavirus Disease (COVID-19) Using X-ray Images and Deep Convolutional Neural Networks," Mar. 2020, Accessed: May 01, 2020. [Online]. Available: <http://arxiv.org/abs/2003.10849>.
- [4] O'Shea, K. & Nash, R. *An Introduction to Convolutional Neural Networks*. (2015).
- [5] A. Iqbal Khan, J. Latief Shah, and M. Bhat, "CoroNet: A Deep Neural Network for Detection and Diagnosis of Covid-19 from Chest X-ray Images."
- [6] M. Rahimzadeh and A. Attar, "A New Modified Deep Convolutional Neural Network for Detecting COVID-19 from X-ray Images," Apr. 2020, Accessed: May 01, 2020. [Online]. Available: <http://arxiv.org/abs/2004.08052>.
- [7] A. Abbas, M. Abdelsamea, and M. Gaber, "Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network," medRxiv, p. 2020.03.30.20047456, Apr. 2020, doi: 10.1101/2020.03.30.20047456.
- [8] Q. Yan et al., "COVID-19 Chest CT Image Segmentation -- A Deep Convolutional Neural Network Solution," Apr. 2020, Accessed: May 01, 2020. [Online]. Available: <http://arxiv.org/abs/2004.10987>.
- [9] N. S. Punn and S. Agarwal, "Automated diagnosis of COVID-19 with limited posteroanterior chest X-ray images using fine-tuned deep neural networks," Apr. 2020, Accessed: May 01, 2020. [Online]. Available: <http://arxiv.org/abs/2004.11676>
- [10] D. Singh, V. Kumar, Vaishali, and M. Kaur, "Classification of COVID-19 patients from chest CT images using multi-objective differential evolution-based convolutional neural networks," *European journal of clinical microbiology & infectious diseases* : official publication of the European Society of Clinical Microbiology, Apr. 2020, doi: 10.1007/s10096-020-03901-z.
- [11] L. Wang and A. Wong, "COVID-Net: A Tailored Deep Convolutional Neural Network Design for Detection of COVID-19 Cases from Chest X-Ray Images," Mar. 2020, Accessed: May 01, 2020. [Online]. Available: <http://arxiv.org/abs/2003.09871>.
- [12] J. Zhao, Y. Zhang, X. He, and P. Xie, "COVID-CT-Dataset: A CT Scan Dataset about COVID-19," Mar. 2020, Accessed: May 01, 2020. [Online]. Available: <http://arxiv.org/abs/2003.13865>.
- [13] E. E.-D. Hemdan, M. A. Shouman, and M. E. Karar, "COVIDX-Net: A Framework of Deep Learning Classifiers to Diagnose COVID-19 in X-Ray Images," Mar. 2020, Accessed: May 01, 2020. [Online]. Available: <http://arxiv.org/abs/2003.11055>.