

# Deep Learning Transfer with AlexNet for Chest X-Ray COVID-19 Recognition

E. Cortés, and S. Sánchez

**Abstract**— The COVID-19 is a new disease, the infection can cause respiratory illness with symptoms such as cough, fever, and, in severe cases, pneumonia. Early diagnosis is crucial for the correct treatment to reduce as much as possible the stress in the healthcare system. The need for auxiliary diagnostic tools has increased as there are no accurate automated toolkits available. Application of advanced artificial intelligence techniques coupled with radiological imaging can be helpful for the accurate detection of this disease. In this study, we have applied learning transfer to a convolutional neural network known as AlexNet for chest X-ray recognition between COVID-19 and Healthy. We have fine tuned AlexNet for our specific problem. The first layer, which works with color images, is replaced for images in a single intensity. 11,312 chest X-ray images from six public databases were used to train the network. Among them are samples of healthy people and samples that present the effect of pneumonia and COVID-19 diseases. The results prove that deep learning with chest X-ray images can extract significant biomarkers related to COVID-19, since the obtained accuracy, sensitivity, and specificity were 96.5%, 98.0%, and 91.7%, respectively. Receiver operating characteristic analysis and confusion matrices are used to validate the results of the fine-tuned AlexNet network.

**Index Terms**— AlexNet, Chest X-ray, Convolutional Neural Network, COVID-19, Deep Learning Transfer, Recognition.

## I. INTRODUCCIÓN

Una enfermedad severa del sistema respiratoria fue recientemente reportada en Wuhan, Hubei provincia de China [1], y para el 25 de enero de 2020, al menos 1,975 casos habían sido reportados desde que el primer paciente fue hospitalizado el 12 de diciembre de 2019, investigaciones epidemiológicas han sugerido que el brote estuvo asociado al mercado de comida del mar en Wuhan. Más tarde organizaciones médicas determinaron que se trataba de un nuevo genoma viral denominado 2019-nCoV (COVID-19), el cual está asociado con un coronavirus de humano y de murciélago. La infección por coronavirus sorprendió al mundo por su rápida expansión, al tener impacto en billones de personas [2]. Gracias al alto volumen de pruebas en máquinas de detección del COVID-19, se ha alcanzado hasta inicios de abril 1.4 millones de diagnósticos confirmados, desafortunadamente millones de pruebas son todavía necesarias [3].

E. Cortés está en la Universidad del Istmo Campus Tehuantepec, Ingeniería en Computación, Oax., México C.P. 70760 (e-mail: cope144@gmail.com).

S. Sánchez está en la Universidad del Istmo Campus Tehuantepec, Licenciatura en Matemáticas Aplicadas. Oax., México C.P. 70760 (e-mail: ssanys1@hotmail.com)

También se han realizado pruebas alternativas basadas en ácido nucleico y serología mediante tomografía computarizada (TC) [4, 5], ampliamente adoptados para probar casos COVID-19. Hasta la fecha la mayoría de herramientas de diagnóstico basadas en TC son desarrolladas en hospitales con equipos caros y donde se requiere la experiencia de radiólogos [6, 7]. La amplia disponibilidad de rayos X de pecho en diversos tratamientos para el cuidado de salud, los hace una atractiva opción para una rápido, exacto y menos caro diagnóstico de COVID-19. Actualmente, el problema es tener el grupo de radiólogos certificados capaces de diferenciar casos positivos de COVID-19, de otras enfermedades del pulmón, y de condiciones normales. En años recientes Deep Learning ha logrado un gran desempeño en el área de clasificación de imágenes médicas [8], los resultados son similares a los de un experto humano al resolver tareas como la clasificación en enfermedades de pulmón, detección de metástasis en cáncer de pecho, lesiones de la piel, identificar retinopatía diabética, Alzheimer, reconstrucción por imágenes de resonancia magnética y tomografías computarizadas. La detección de COVID-19 por medio de imágenes, es uno de los mayores retos alrededor del mundo.

En este estudio se demuestra que la transferencia de aprendizaje a la CNN AlexNet, ofrece una solución de bajo costo, rápida y automática, para proveer un diagnóstico relacionado con los síntomas causados por la enfermedad Coronavirus. Esto mediante la clasificación de imágenes de rayos X de pecho de personas en dos categorías (COVID-19, normal). Desde una perspectiva clínica y psicológica la neumonía causada por Covid-19 contiene un alto grado de similaridad con la neumonía tradicional [26-28].

Las principales contribuciones en este trabajo son:

1. Demostrar el desempeño de AlexNet en la clasificación de imágenes de rayos X de pecho con COVID-19.
2. Con la transferencia de aprendizaje a la red AlexNet conseguimos un diagnóstico preciso de bajo costo, rápido y automático en la detección de COVID-19.
3. A partir de seis bases de datos públicas [30-35] se construyó una colección de imágenes de rayos X con COVID-19.
4. Para el problema de desequilibrio de datos [45-49], se emplea aumento de datos (*augmented data*) (AD) [46-52].
5. Se contrastan los resultados obtenidos en nuestro estudio con otros relacionados.

## II. TRABAJOS RELACIONADOS

Las imágenes médicas juegan un rol fundamental en la lucha global contra el COVID-19, esto abrió un nuevo reto para la comunidad de investigadores en el mundo. Trabajos recientes como el de Pereira *et al.* [49] incluyen análisis de rayos X de pecho que permiten discriminar entre neumonía por bacteria y neumonía viral, y han alcanzado una exactitud de 99.01%. Trabajos como el de Mohammad *et al.* [53] aplican aprendizaje profundo incluyendo redes generativas adversarias para acelerar el proceso de diagnóstico y tratamiento de COVID-19. Trabajos pioneros incluyen en su investigación TC [54, 55] para una detección precisa de COVID-19 basado en múltiples muestras de imágenes 3D. En contraste, en [56] y [57] se emplean rayos X, imágenes médicas más accesibles a una mayor parte de la población. Además, los rayos X están disponibles en la mayoría de los hospitales [58]. Un importante estudio lo realizó Abu *et al.* [59], en donde mencionan que, en situación de pandemia, también son útiles los dispositivos y técnicas tales como internet de las cosas (IoT), webcam, drones y robots inteligentes. Debido a la complejidad espacial de los rayos X, algunos trabajos adoptan el diagnóstico binario (COVID vs Sano) y clasificación multiclase (COVID vs Sano vs Neumonía) [55-58], [60-64]. Entre estos trabajos, está el de Ozturk *et al.* en el cual emplean el modelo DarkNet, que produce una exactitud en la clasificación de 98.08%. Trabajos enfocados en analizar distintos modelos de redes neuronales convolucionales son [47], [64-68] en los cuales muestran los resultados de la exactitud en la clasificación. En esa misma línea, Varshni *et al.* [10] analizaron imágenes de rayos X con infección en uno o ambos pulmones. En su estudio evalúan la funcionalidad de modelos de redes neuronales convolucionales pre-entrenadas como VGGNets, Xception, ResNet-50 y DenseNets, y de acuerdo con los resultados estadísticos, determinaron que el mejor resultado fue logrado con la arquitectura DenseNet-169 como extractor de características. Apostolopoulos *et al.* [9] en sus resultados sugieren que el aprendizaje profundo con imágenes de rayos X puede extraer significantes bio-marcadores relacionados con COVID-19, donde la exactitud, sensibilidad y especificidad obtenida es 96.78%, 98.66% y 96.46%, respectivamente. Por otra parte, imágenes de ultrasonido de tiroides han sido empleadas por Sun J. *et al.* [11], quienes proponen un método automático basado en la red AlexNet para la localización y diagnóstico de lesiones benignas y malignas. Después del entrenamiento de la red con 1,488 imágenes con la exactitud fue de 0.8159.

La red neuronal convolucional AlexNet, ha sido empleada por A. Titoriya y S. Sachdeva [12] para diagnosticar cáncer de pecho y analizar imágenes histopatológicas, los autores utilizaron un conjunto de datos de 7,909 imágenes de 82 pacientes para entrenar su modelo. Así mismo, F. Mashrur *et al.* [13] en su documento emplearon AlexNet para localizar características de fibrilación auricular en electrocardiogramas (ECG). Para entrenar la red, emplearon 5,655 lecturas de ECG, inicialmente extrajeron un espectrograma por cada 30 segundos, y después lo convirtieron a imagen RGB con la transformada continua Wavelet. En sus estudios indican que su técnica alcanza 97.9% de exactitud, 98.9% de sensibilidad, y 90.7% en especificidad. Estudios representativos del tema eliminación del virus COVID-19 en heces humanas están en [14-16].

Conjuntos de datos utilizados en investigación en la eliminación del virus en la orina y la sangre se pueden ver en [17], así como también información acerca de cómo el virus es transmitido [18-20]. Lo anterior expone claro ejemplo de cómo las redes neuronales convolutivas tienen impacto significativo en el análisis de imágenes médicas.

## III. DESCRIPCIÓN DEL CONJUNTO DE DATOS

Actualmente un gran número de investigadores, hospitales y organismos de salud, han construido bases de datos de imágenes médicas con información relacionada al COVID-19, como ejemplo Wang *et al.* [32] proporcionan una base de datos compuesta de 108,949 imágenes frontales de rayos X de 32,717 pacientes (recolectadas de 1992 a 2015), estas imágenes están asociadas con 8 patologías torácicas comunes: neumonía, neumotórax, efusión, cardiomegalia, masas, nódulos, infiltración y atelectasias. En este mismo sentido Irvin *et al.* presentan una base de datos de 224,316 de radiografías de rayos X de 65,240 pacientes con presencia de 14 síntomas [35].

Con el fin de no infringir la confidencialidad del paciente, las imágenes de rayos X de pecho para este estudio, fueron recolectadas de seis bases de datos públicas representativas con muestras de COVID-19 [30]-[35], la estructura del conjunto de datos se muestra en Tabla I.

TABLA I  
DESCRIPCIÓN DEL CONJUNTO DE DATOS

Base de datos	(COVID-19) + neumonía	Normal
Kermany <i>et al.</i> [30]	0+3,875	1,341
Chowdhury <i>et al.</i> [31]	215+1,345	1,300
Wang <i>et al.</i> [32]	0+2,562	3,044
Cohen <i>et al.</i> [33]	517+3,418	1,266
Kaggle [34]	0+500	500
Irvin <i>et al.</i> [35]	0+207,689	16,627
<b>Total</b>	<b>219,389</b>	<b>24,078</b>

Es necesario mencionar que las bases de datos existentes cuentan con un número limitado de imágenes de rayos X con COVID-19, con el fin de solucionar el desequilibrio de clases [37]-[45], se construyó una base con métodos de AD [46]-[52], donde fue necesario emplear sobre-muestreo aleatorio (*random over-sampling*) y bajo-muestreo aleatorio (*random under-sampling*) [43]. Los métodos empleados para el AD se describen en la Tabla II.

El desequilibrio de clases puede tomar varias formas, particularmente en el contexto de clasificación binaria (COVID-19 vs normal), comúnmente algunas de las clases pueden estar sobre-representadas o bajo-representadas, para esto, se emplean dos métricas de desequilibrio [36], la primera es denominada *step imbalance*, la cual se define en (1).

$$\mu = \frac{\sum_{i \in \{1 \dots N\}} C_i \text{ es minoría}}{N} \quad (1)$$

Dónde  $C_i$  es un conjunto de ejemplos en la clase  $i$ , y  $N$  es el número total de clases.

El otro parámetro es el radio  $\rho$  [36] que será utilizado para indicar el nivel máximo desequilibrio entre clases, el cual se define en (2).

$$\rho = \frac{\max_i\{C_i\}}{\min_i\{C_i\}} \quad (2)$$

Dónde:  $C_i$  es un conjunto de ejemplos en la clase  $i$ ,  $\max\{C_i\}$  y  $\min\{C_i\}$  son el máximo y mínimo tamaño de clase sobre todas las clases  $i$ . Una base de datos con la misma cantidad de ejemplos en cada clase, tiene una relación de desequilibrio pequeño en  $(\rho, \mu)$ , ver Fig. 1.

TABLA II  
MÉTODOS EMPLEADOS EN EL AUMENTO DE DATOS

Método	Valor
Rotación	$[-15^\circ, +15^\circ]$
Traslación X	$[-50, 50]$
Traslación Y	$[-50, 50]$
Re-escala	$[1.3, 1.5]$
Reflexión X	True
Reflexión Y	False
Saturación color	$[-0.7, -0.1]$
Brillo	$[-0.3, -0.1]$
Contraste	$[1.2, 1.4]$

La base de datos después del AD se observa en la Tabla III.

TABLA III  
DESCRIPCIÓN DEL CONJUNTO DE DATOS RESULTANTE

Base de datos	(COVID-19) + neumonía	Normal
Kermany <i>et al.</i> [30]	387	661
Chowdhury <i>et al.</i> [89]	808	630
Wang <i>et al.</i> [32]	256	304
Cohen <i>et al.</i> [33]	1,375	626
Kaggle [34]	500	50
Irvin <i>et al.</i> [35]	2,076	3,589
<b>Total ejemplos</b>	<b>5,452</b>	<b>5,860</b>

#### IV. ALEXNET - RED NEURONAL CONVOLUCIONAL

AlexNet fue desarrollada por [21], y estudiada en [22], su aceptable desempeño entre velocidad y exactitud fue analizado en [23]. AlexNet fue la red ganadora en el desafío de reconocimiento visual a gran escala en el ILSVRC 2012 (ImageNet Large Scale Visual Recognition Challenge). ImageNet es un conjunto de datos de más de 15 millones de imágenes en alta resolución etiquetadas en 1000 categorías. La salida de AlexNet es un vector de 1000 números, donde el  $i$ -ésimo elemento es interpretado como la probabilidad de que la imagen de entrada pertenece a la  $i$ -ésima clase. Además, la suma de todos los elementos del vector es 1. AlexNet consiste de 5 capas de convolución, 7 capas ReLU, 3 capas Pooling, 3 capas totalmente conectadas y una capa Softmax.

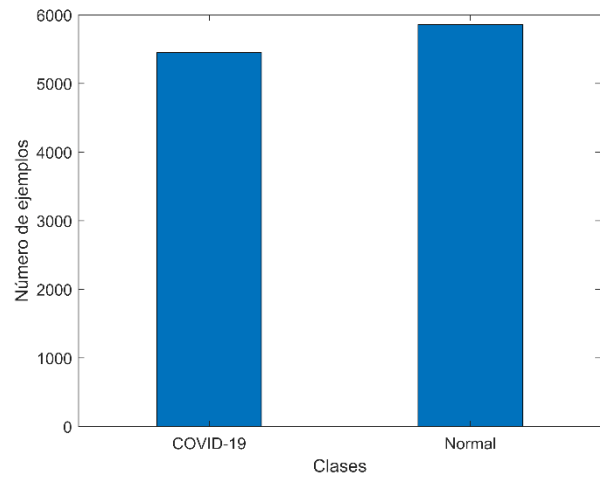


Fig. 1. Distribución de desequilibrio entre clases,  $\rho = 1.1313$ ,  $\mu = 0.5$ .

#### A. Pooling

Las primeras dos capas son seguidas de la operación *Pooling*, la cual es utilizada para disminuir el tamaño de la muestra. AlexNet utiliza una ventana de Pooling de 3x3 con pasos de 2 entre ventanas adyacentes.

#### B. Softmax

La función softmax toma como entrada un vector de números reales (clases), y lo normaliza con una distribución de  $M$  probabilidades proporcionales al exponencial del número de entradas (clases).

#### C. ReLU

Una importante característica de AlexNet es el uso de ReLU (Rectified Linear Unit). Comúnmente funciones de activación Tanh o Sigmoidal son usadas para entrenar redes neuronales.

#### V. METODOLOGÍA

El modelo propuesto modifica las 2 primeras capas de AlexNet como sigue: la primera capa *input*: es modificada para aceptar imágenes de dimensión 227x227 en lugar de 227x227x3, la segunda capa *conv1*: es modificada para calcular 96 descriptores por convolución en ventanas 11x11, en lugar de 11x11x3, y la tercera capa *relu1*: es modificada para realizar la operación de rectificador lineal conectada con la capa *conv1*.

Para diferenciar entre dos clases (COVID-19, Normal) en lugar de 1000, la capa 23 *fc* (*fully connected*) es reemplazada por otra capa *fc special* totalmente conectada de dos nodos (clases), y con esto alimentar al clasificador *Softmax* de la capa 24 *prob*, con 2 nodos de salida. La Tabla IV muestra la arquitectura de AlexNet previo a su modificación.

TABLA IV  
ARQUITECTURA DE ALEXNET

Capa	Nombre de la capa	Tipo de capa	Detalles de la capa
1	input	Imagen de entrada	227x227x3 dimensión de la imagen
2	'conv1'	Convolución	96 11x11x3 convoluciones
3	'relu1'	ReLU	ReLU
4	'norm1'	Normalización	Normalización
5	'pool1'	Pooling	3x3 max pooling
6	'conv2'	Convolución	convolución 2 grupos de 128 5x5x48
7	'relu1'	ReLU	ReLU
8	'norm2'	Normalización	normalización
9	'pool2'	Pooling	3x3 max pooling
10	'conv3'	Convolución	384 convoluciones de 3x3x256
11	'relu3'	ReLU	ReLU
12	'conv4'	Convolución	2 grupos de convoluciones de 192 3x3x192
13	'relu4'	ReLU	ReLU
14	'conv5'	Convolución	2 grupos convoluciones de 128 3x3x192
15	'relu5'	ReLU	ReLU
16	'pool3'	Pooling	3x3 max pooling
17	'fc6'	Completamente Conectada	Capa totalmente conectada de 4096
18	'relu6'	ReLU	ReLU
19	'drop6'	Dropout	50% dropout
20	'fc7'	Completamente Conectada	Capa totalmente conectada de 4096
21	'relu7'	ReLU	ReLU
22	'drop7'	Dropout	50% dropout
23	'fc8'	Completamente Conectada	Capa totalmente conectada de 1000 clases
24	'prob'	Softmax	Softmax
25	'output'	Clasificación	Entropía cruzada 1000 clases

La arquitectura adaptada para realizar la transferencia de aprendizaje se puede ver en Tabla V.

TABLA V  
CAPAS DE ALEXNET ADAPTADAS PARA LEARNING TRANSFER

Capa	Nombre de la capa	Tipo de capa	Detalles de la capa
1	input	Imagen de entrada	227x227 dimensión de la imagen
2	'conv1'	Convolución	96 11x11 convoluciones
23	'fc special'	Completamente Conectada	Capa totalmente conectada de 2 clases
24	'softmax'	Softmax	Softmax
25	'output'	Clasificación	Entropía cruzada 2 clases

### A. Extracción de Características

Las capas que realizan la extracción de características son de tres tipos: Convolución, ReLU, y Pooling. AlexNet tiene 5 capas de convolución, (2, 6, 12, 10, 14); la capa 2 (primera convolución) tiene como entrada las imágenes de rayos X de pecho, las cuales pasan a través de un conjunto de filtros convolucionales. En la capa 6 (segunda convolución), se obtienen 2 grupos de 128 kernels. La capa 10 (tercera convolución), se producen 384 kernels. La capa 12 (cuarta convolución), produce 2 grupos de 192 kernels, y la capa 14 (quinta convolución), produce 2 grupos de 128 kernels. El objetivo de las capas de convolución es preservar patrones de bordes, estas características son evidentemente aprendidas a

una menor resolución. La Fig. 2 muestra 36 kernels de cada convolución.

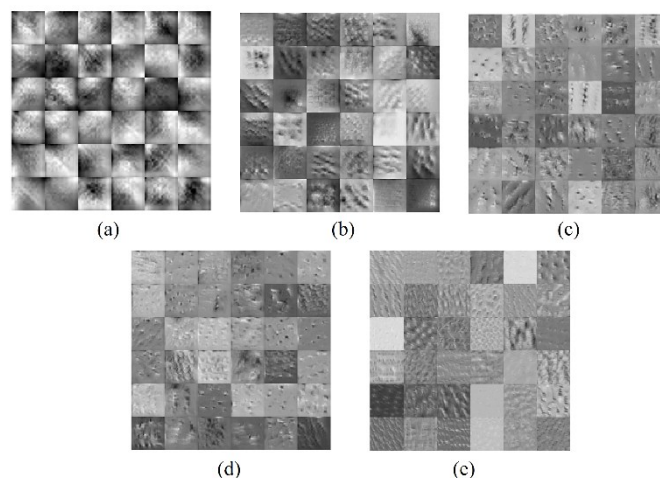


Fig. 2. Extracción de características en (a) convolución 1, (b) convolución 2, (c) convolución 3, (d) convolución 4, y (e) convolución 5.

Las capas ReLU permiten un entrenamiento más rápido y efectivo, mapean los valores negativos, y mantienen los valores positivos. AlexNet tiene 7 capas ReLU, (3, 7, 11, 13, 15, 18 y 21). La Fig. 3, muestra 36 kernels de cada capa ReLU. Las capas Pooling simplifican la salida y disminuyen la resolución (*downsampling*), al reducir el número de parámetros que la red necesita aprender. AlexNet tiene tres capas Pooling: (5, 9 y 16). La operación pooling produce una imagen relativa donde se resalta la localización de la enfermedad [25]. El resultado en las capas Pooling se puede observar en la Fig. 4.

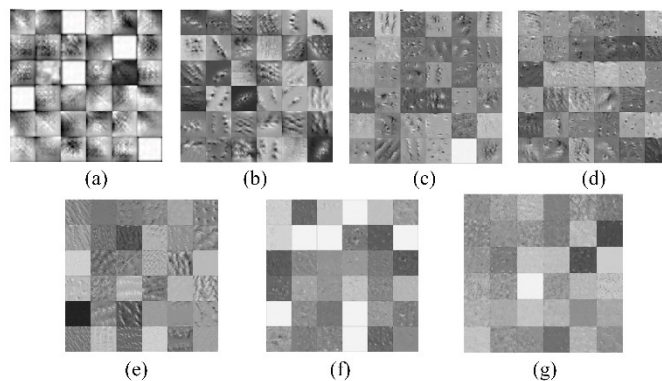


Fig. 3. Extracción de características en las capas: (a) ReLU 1, (b) ReLU 2, (c) ReLU 3, (d) ReLU 4, (e) ReLU 5, (f) ReLU 6, y (g) ReLU 7.




Fig. 4. Extracción de características en las capas: (a) pooling 1, (b) pooling 2, y (c) pooling 3.

## VI. RESULTADOS EN LA TRANSFERENCIA DE APRENDIZAJE PROFUNDA

En los experimentos realizados se asignó la etiqueta *COVID-19* (clase 1) y *Normal* (clase 2). Para esto, el conjunto de datos fue dividido en dos grupos, ver Tabla VI.

TABLA VI  
CONJUNTO DE DATOS

Conjunto de datos	COVID-19	Normal
Grupo 1 - Entrenamiento	5352	5760
Grupo 2 - Validación	100	100

Para transferir el aprendizaje, entrenamos la red AlexNet con el empleo del gradiente descendente estocástico y con un tamaño de lote (batch) de 100 ejemplos, momentum de 0.9 y una tasa de aprendizaje inicial de 0.0004, inicializamos los pesos en cada capa con distribución Gaussiana con media cero y desviación 0.01. También, inicializamos con el valor de 1 los *bias* de la segunda, sexta, decima, decimosegunda y decimocuarta capa de convolución, así como también las capas totalmente conectadas. Para el entrenamiento, alimentamos la red AlexNet por 6 ciclos, con el primer conjunto de datos (entrenamiento), la cual tomo 55 minutos y 42 segundos. Las pruebas se realizaron en un GPU Intel i7 NVIDIA GeForce GTX 1050, Memoria 16GB.

### A. Métricas Empleadas

Al considerar la tarea de clasificación en CNN, se consideraron las siguientes métricas.

1. Casos de enfermedad clasificados correctamente (Verdaderos Positivos, *VP*).
2. Casos de enfermedad clasificados incorrectamente (Verdaderos Negativos, *VN*).
3. Casos normales clasificados correctamente (Falsos Positivos, *FP*).
4. Casos normales clasificados incorrectamente (Falsos Negativos, *FN*).

Donde:

*VP*: se refiere a los casos clasificados con neumonía.

*VN*: se refiere a los casos con neumonía clasificados como normales.

*FP*: se refiere a los casos clasificados como normales.

*FN*: se refiere a los casos normales, clasificados como neumonía.

Basado en esas métricas, calculamos la exactitud, sensibilidad y especificidad del modelo. Las ecuaciones que explican las métricas antes mencionadas son (3), (4) y (5)

$$exactitud = \frac{VP+VN}{VP+VN+FP+FN} \quad (3)$$

$$sensibilidad = \frac{VP}{VP+FN} \quad (4)$$

$$especificidad = \frac{VN}{VN+FP} \quad (5)$$

### B. Gráficas de Resultados del Grupo 1 (Entrenamiento)

Los resultados del grupo 1 se muestran en la una matriz de confusión y gráfica ROC de la Fig. 5.

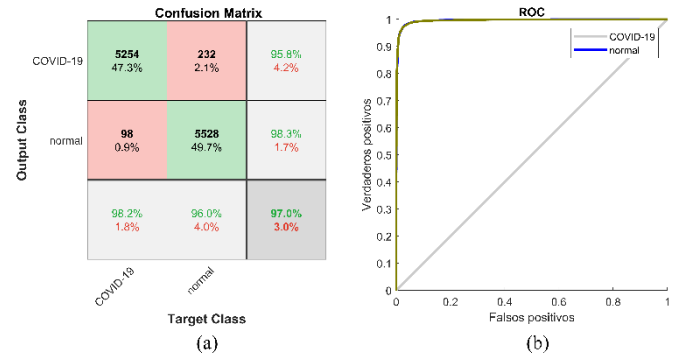


Fig. 5. Resultados en el reconocimiento de COVID-19 con el conjunto de datos de entrenamiento, 97.0% de exactitud, (a) matriz de confusión, y (b) gráfica ROC.

### C. Gráficas de Resultados del Grupo 2 (Validación)

Para validar el desempeño de la transferencia de aprendizaje de AlexNet en el reconocimiento de COVID-19, se empleó el segundo grupo de datos, la una matriz de confusión y gráfica ROC se muestran en la Fig. 6.




Fig. 6. (a) Matriz de confusión, y (b) grafica ROC, donde se muestra el desempeño en la clasificación 96.5% de exactitud en el reconocimiento de COVID-19 con el conjunto de datos de prueba.

### D. Resultados

La Tabla VII ilustra los valores para *VP*, *FP*, *VN* y *FN*, de los dos grupos de datos.

TABLA VII  
VP, FP, VN, Y FN

CNN AlexNet	VP	FP	VN	FN
Entrenamiento	5254	98	5528	232
Validación	97	3	96	4

Los resultados de las métricas *exactitud*, *sensibilidad* y *especificidad*, con los dos grupos de datos, son ilustrados en la Tabla VIII.

TABLA VIII  
EXACTITUD, SENSIBILIDAD Y ESPECIFICIDAD

CNN AlexNet	Exactitud	Sensibilidad	Especificidad
Entrenamiento	97.0%	98.9%	92.2%
Validación	<b>96.5%</b>	98.0%	91.7%

En Fig. 7, se muestra el funcionamiento de AlexNet, donde se puede observar los resultados de la clasificación de 16 imágenes.

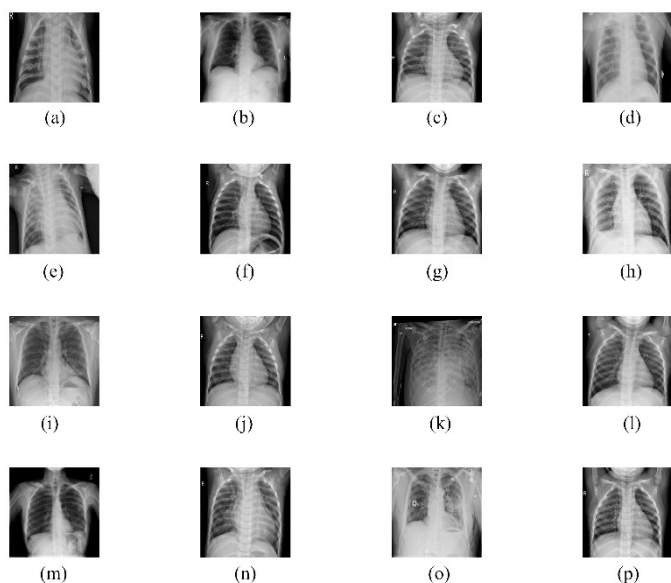


Fig. 7. Resultados de desempeño en el reconocimiento con 16 imágenes empleando el conjunto de datos de prueba, (a) COVID-19: 100%, (b) normal: 97%, (c) normal: 99.8%, (d) COVID-19: 100%, (e) COVID-19: 100%, (f) normal: 99.2%, (g) normal: 99.7%, (h) COVID-19: 99.3%, (i) COVID-19: 97.6%, (j) normal: 99.9%, (k) COVID-19: 78.8%, (l) normal: 99.9%, (m) normal: 99.8%, (n) COVID-19: 100%, (o) COVID-19: 88.6%, (p) normal: 100%.

## VII. CONCLUSIONES

Una rápida detección del COVID-19 en pacientes, es vital para prevenir el contagio de la enfermedad a otras personas, el presente estudio permite ofrecer un diagnóstico de bajo costo, rápido y automático de la enfermedad COVID-19. Se demostró que el desempeño de AlexNet es mejor en comparación de otros estudios (Tabla IX), donde se obtuvo una exactitud de 96.5% en la clasificación, solo por debajo de [57, 70], esto mediante la transferencia de aprendizaje de un conjunto de 11,312 imágenes de rayos X de pecho obtenidas de seis bases de datos [30]-[35]. También se demuestra que, el desempeño de la clasificación depende de la arquitectura empleada y los parámetros de cada arquitectura. Debido a una limitación en imágenes de rayos X con COVID-19, realizamos sobre-muestreo aleatorio (*random over-sampling*) y bajo-muestreo aleatorio (*random under-sampling*) [43], esto con el fin de equilibrar el conjunto de datos de entrenamiento y validación. La base de datos empleada en este estudio está disponible en <https://drive.google.com/drive/folders/1H8cJol84M9DLFBYT-ACqwxX9pCBT-SmK?usp=sharing>. Para demostrar el desempeño, realizamos la calibración de AlexNet en las capas

1, 2, 23, 24 y 25, presentamos los resultados en matrices de confusión y graficas de curva ROC.

Basado en los resultados, se demostró que la transferencia de aprendizaje con AlexNet puede tener efectos significativos en la detección automática y extracción de características relacionadas al diagnóstico de COVID-19.

TABLA IX  
COMPARATIVO - ESTADO DEL ARTE

Estudio	Tipo de imagen	Casos	Método empleado	Exactitud %
Brunese et al. [57]	Rayos X	Neumonía=2753 Normal=3520	VGG-16	97
Xu et al. [69]	TC	COVID=219 Neumonía=224 Normal=175	ResNet	86.7
Narin et al. [70]	Rayos X	COVID=50 Normal=50	Deep CNN ResNet-50	98
Wang et al. [71]	Rayos X	COVID=5526 Normal=8066	COVID-Net	92.4
Apostolopoulos et al. [9]	Rayos X	COVID=224 Neumonía=700 Normal=504	VGG-19	93.48
Sethy et al. [72]	Rayos X	COVID=25 Normal=25	ResNet-50+SVM	95.38
<b>Nuestro estudio</b>	<b>Rayos X</b>	<b>COVID=5452 Normal=5860</b>	<b>AlexNet</b>	<b>96.5</b>

Se pueden mencionar algunos aspectos relacionados a las limitaciones en este estudio, en particular, buscamos enriquecer la colección de ejemplos a partir de las seis bases de datos públicas con muestras de COVID-19, con el fin de construir una colección más extensa. Además, en el futuro es posible enfocarse en la distinción de pacientes con síntomas virales similares a la neumonía tradicional [26-28], en lugar de solo COVID-19, ya que otros síntomas podrían no ser visualizados en las imágenes de rayos X. Finalmente, a pesar de que un apropiado tratamiento no es determinado únicamente por imágenes de rayos X, puede ser un indicador inicial para tomar medidas de cuarentena en muestras positivas, hasta que una examinación más completa sea realizada. Relacionado a esto, la ventaja de una automática detección de COVID-19, ayuda a la reducción contagios debido a la exposición de enfermeras y personal médico.

## REFERENCIAS

- [1] F. Wu, S. Zhao, B. Yu, Y. Chen, M. Wang, W. Song, & M. L. Yuan, (2020). A new coronavirus associated with human respiratory disease in China. *Nature*, 579(7798), pp. 265-269.
- [2] K. R. Lee, Y. Luo, R. Kirpich, A. Rothenberg, R. Hyman, J. M. Yan, P. and G. Chowell, Real-time forecasts of the COVID-19 epidemic in China from February 5th to February 24th, 2020. *Infectious Disease Modelling*, 5: pp. 256-263, 2020.
- [3] L. Yan, H. Zhang, T. Xiao, Y. Wang, M. Guo, Y. Sun, C. Tang, X. Jing, L. Li, S. Zhang, M. Xiao, Y. Cao, H. Chen, Y. Ren, Prediction of criticality in patients with severe Covid-19 infection using three clinical features: a machine learning-based prognostic model with clinical data in Wuhan. *medRxiv preprint* doi: <https://doi.org/10.1101/2020.02.27.20028027>, 1-18, 2020.
- [4] X. Li, Chengyin Li, and Dongxiao Zhu. Covid-mobilexpert: On-device covid-19 screening using snapshots of chest x-ray, 2020.



- [5] S. Salehi, A. Abedi, S. Balakrishnan, and A. Gholamrezanezhad. Coronavirus disease 2019 (covid-19): a systematic review of imaging findings in 919 patients. *American Journal of Roentgenology*, pp.1–7, 2020.
- [6] E. Y. Lee, M. Y. Ng, and P. L. Khong. Covid-19 pneumonia: what has taught us? *The Lancet Infectious Diseases*, 20(4):384–385, 2020.
- [7] H. X. Bai, B. Hsieh, Z. Xiong, K. Halsey, J. Whae Choi, T. My Linh Tran, I. Pan, L. Shi, D. Wang, J. Mei, et al. Performance of radiologists in differentiating covid-19 from viral pneumonia on chest ct. *Radiology*, pp. 200-823, 2020.
- [8] L. Li, L. Qin, Z. Xu, Y. Yin, X. Wang, B. Kong, J. Bai, Y. Lu, Z. Fang, Q. Song, et al. Artificial intelligence distinguishes covid-19 from community acquired pneumonia on chest ct. *Radiology*, page 905, 2020.
- [9] I. D. Apostolopoulos, T. A. Mpesiana, Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks. *Phys Eng Sci Med* (2020). <https://doi.org/10.1007/s13246-020-00865-4>.
- [10] D. Varshni, K. Thakral, L. Agarwal, R. Nijhawan and A. Mittal, "Pneumonia Detection Using CNN based Feature Extraction," 2019 IEEE International Conference on Electrical, Computer and Communication Technologies (ICECCT), Coimbatore, India, 2019, pp. 1-7.
- [11] J. Sun, T. Sun, Y. Yuan, X. Zhang, Y. Shi, & Y. Li. (2018, November). Automatic Diagnosis of Thyroid Ultrasound Image Based on FCN-AlexNet and Transfer Learning. In 2018 IEEE 23rd International Conference on Digital Signal Processing (DSP) (pp. 1-5). IEEE.
- [12] A. Tituriya and S. Sachdeva, "Breast Cancer Histopathology Image Classification using AlexNet," 2019 4th International Conference on Information Systems and Computer Networks (ISCON), Mathura, India, 2019, pp. 708-712.
- [13] F. R. Mashrur, A. Dutta Roy and D. K. Saha, "Automatic Identification of Arrhythmia from ECG Using AlexNet Convolutional Neural Network," 2019 4th International Conference on Electrical Information and Communication Technology (EICT), Khulna, Bangladesh, 2019, pp. 1-5.
- [14] Y. Xing, W. Ni, Q. Wu, W. Li, G. Li, W. Wang, J. Tong, X. Song, G. Wing-Kin Wong, Q. Xing, Prolonged viral shedding in feces of pediatric patients with coronavirus disease 2019, *Journal of Microbiology, Immunology and Infection*, 2020, ISSN 1684-1182, <https://doi.org/10.1016/j.jmii.2020.03.021>.
- [15] X. Ma, L. Su, Y. Zhang, X. Zhang, Z. Gai, Z. Zhang, Do children need a longer time to shed SARS-CoV-2 in stool than adults? *Journal of Microbiology, Immunology and Infection*, 2020, ISSN 1684-1182.
- [16] I. L. Lo, C. Lio, H. Cheong, C. Lei, TH. Cheong, X. Zhong, Y. Tian, NN. Sin. Evaluation of SARS-CoV-2 RNA shedding in clinical specimens and clinical characteristics of 10 patients with COVID-19 in Macau. *Int J Biol Sci* 2020; 16(10):1698-1707. doi: 10.7150/ijbs.45357.
- [17] B. E. Young, S. Ong, S. Kalimuddin, et al. Epidemiologic Features and Clinical Course of Patients Infected With SARS-CoV-2 in Singapore. *JAMA*. 2020;323(15):1488–1494. doi:10.1001/jama.2020.3204.
- [18] Y. Chen, L. Chen, Q. Deng, et al. The presence of SARS-CoV-2 RNA in the feces of COVID-19 patients. *J Med Virol*. 2020; 1–8. <https://doi.org/10.1002/jmv.25825>.
- [19] K. Yuen, Z. Ye, S. Fung, et al. SARS-CoV-2 and COVID-19: The most important research questions. *Cell Biosci* 10, 40 (2020). <https://doi.org/10.1186/s13578-020-00404-4>.
- [20] J. Won, S. Lee, M. Park, T. Kim, M. Park, B. Choi, D. Kim, H. Chang, V. Kim, C. J. Lee. Development of a Laboratory-safe and Low-cost Detection Protocol for SARS-CoV-2 of the Coronavirus Disease 2019 (COVID-19). *Exp Neurobiol* -0001;0:- <https://doi.org/10.5607/en20009>.
- [21] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Adv. Neural Inf. Process. Syst.*, pp. 1–9, 2012.
- [22] H. C. Shin, H. R. Roth, M. Gao, L. Lu, Z. Xu, I. Noguees, and R. M. Summers, "Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning," *IEEE Transactions on Medical Imaging*, vol. 35, no. 5, pp. 1285-1298, 2016.
- [23] K. Chatfield, K. Simonyan, A. Vedaldi, and A. Zisserman. "Return of the devil in the details: Delving deep into convolutional nets. In *British Machine Vision Conference*, arXiv preprint arXiv:1405.3531, 2014.
- [24] G. E. Hinton, N. Srivastava, A. Krizhevsky, I. Sutskever, & R. R. Salakhutdinov (2012). Improving neural networks by preventing co-adaptation of feature detectors. arXiv preprint arXiv:1207.0580.
- [25] E. C. Orosco, J. G. Amorós, Gimenez, J. A. & C. M. Soria, (2019). Deep learning-based classification using Cumulants and Bispectrum of EMG signals. *IEEE Latin America Transactions*, 17(12), 1946-1953.
- [26] H.X. Bai, B. Hsieh, Z. Xiong, K. Halsey, J.W. Choi, T.M.L. Tran, I. Pan, L.-B. Shi, D.-C. Wang, J. Mei, et al., Performance of radiologists in differentiating COVID-19 from viral pneumonia on chest CT, *Radiology* (2020) 200823.
- [27] M. Chung, A. Bernheim, X. Mei, N. Zhang, M. Huang, X. Zeng, J. Cui, W. Xu, Y. Yang, Z.A. Fayad, et al., CT imaging features of 2019 novel coronavirus (2019-nCoV), *Radiology* (2020) 200230.
- [28] Bai, H. X., Hsieh, B., Xiong, Z., Halsey, K., Choi, J. W., Tran, T. M. L., ... & Jiang, X. L. (2020). Performance of radiologists in differentiating COVID-19 from viral pneumonia on chest CT. *Radiology*.
- [29] D. Verma, C. Bose, N. Tufchi, K. Pant, V. Tripathi, and A. Thapliyal, "An efficient framework for identification of Tuberculosis and Pneumonia in chest X-ray images using Neural Network," *Procedia Computer Science*, vol. 171, pp. 217–224, 2020.
- [30] D. S. Kermay *et al.*, "Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning," *Cell*, vol. 172, no. 5, pp. 1122-1131.e9, Feb. 2018. <https://data.mendeley.com/datasets/rscbjbr9sj/3>
- [31] M. E. H. Chowdhury *et al.*, "Can AI Help in Screening Viral and COVID-19 Pneumonia?" *IEEE Access*, vol. 8, pp. 132665–132676, 2020. <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>
- [32] X. Wang, Y. Peng, L. Lu, Z. Lu, M. Bagheri, and R. M. Summers, "ChestX-Ray8: Hospital-Scale Chest X-Ray Database and Benchmarks on Weakly-Supervised Classification and Localization of Common Thorax Diseases," *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Jul. 2017. <https://nihcc.app.box.com/v/ChestXray-NIHCC>
- [33] J. P. Cohen, Morrison, P., Dao, L., Roth, K., Duong, T. Q., & Ghassemi, M. (2020). Covid-19 image data collection: Prospective predictions are the future. arXiv preprint arXiv:2006.11988. 2. <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>
- [34] <https://www.kaggle.com/pranavraikokte>
- [35] J. Irvin *et al.*, "CheXpert: A Large Chest Radiograph Dataset with Uncertainty Labels and Expert Comparison," *Proceedings of the AAAI Conference on Artificial Intelligence*, vol. 33, pp. 590–597, Jul. 2019. <https://stanfordmlgroup.github.io/competitions/chexpert/>
- [36] M. Buda, A. Maki, and M. A. Mazurowski, "A systematic study of the class imbalance problem in convolutional neural networks," *Neural Networks*, vol. 106, pp. 249–259, Oct. 2018.
- [37] R. A. Bauder, Khoshgoftaar, T. M., & Hasanin, T. (2018, December). An empirical study on class rarity in big data. In *2018 17th IEEE international conference on machine learning and applications (ICMLA)* (pp. 785-790). IEEE.
- [38] R. Anand, K. G. Mehrotra, C. K. Mohan, and S. Ranka, "An improved algorithm for neural network classification of imbalanced training sets," *IEEE Transactions on Neural Networks*, vol. 4, no. 6, pp. 962–969, 1993.
- [39] S. H. Khan, M. Hayat, M. Bennamoun, & R. Togneri (2017). Cost-sensitive learning of deep feature representations from imbalanced data. *IEEE transactions on Neural Networks and Learning systems*, 29(8), pp. 3573-3587.
- [40] S. Pouyanfar, Tao, Y., Mohan, A., Tian, H., Kaseb, A. S., Gauan, K., ... & Shyu, M. L. (2018, April). Dynamic sampling in convolutional neural networks for imbalanced data classification. In *2018 IEEE conference on multimedia information processing and retrieval (MIPR)* (pp. 112-117). IEEE.

- [41] B. Krawczyk, (2016). Learning from imbalanced data: open challenges and future directions. *Progress in Artificial Intelligence*, 5(4), pp. 221-232.
- [42] H. Lee, M. Park, & J. Kim. (2016, September). Plankton classification on imbalanced large scale database via convolutional neural networks with transfer learning. In *2016 IEEE International Conference on Image Processing (ICIP)* (pp. 3713-3717). IEEE.
- [43] J. M. Johnson, & T. M. Khoshgoftaar, (2019). Survey on deep learning with class imbalance. *Journal of Big Data*, 6(1), 27.
- [44] R. A. Bauder, & T. M. Khoshgoftaar, (2018). The effects of varying class distribution on learner behavior for medicare fraud detection with imbalanced big data. *Health Information Science and Systems*, 6(1), p 9.
- [45] S. Wang, W. Liu, J. Wu, L. Cao, Q. Meng, and P. J. Kennedy, "Training deep neural networks on imbalanced data sets," in *Proceedings of the International Joint Conference on Neural Networks*, 2016, doi: 10.1109/IJCNN.2016.7727770.
- [46] D. Verma, C. Bose, N. Tufchi, K. Pant, V. Tripathi, and A. Thapliyal, "An efficient framework for identification of Tuberculosis and Pneumonia in chest X-ray images using Neural Network," in *Procedia Computer Science*, 2020, doi: 10.1016/j.procs.2020.04.023.
- [47] H. Panwar, P. K. Gupta, M. K. Siddiqui, R. Morales-Menendez, and V. Singh, "Application of deep learning for fast detection of COVID-19 in X-Rays using nCOVnet," *Chaos, Solitons and Fractals*, 2020, doi: 10.1016/j.chaos.2020.109944.
- [48] P. Y. Simard, D. Steinkraus, and J. C. Platt, "Best practices for convolutional neural networks applied to visual document analysis," in *Proceedings of the International Conference on Document Analysis and Recognition, ICDAR*, 2003, doi: 10.1109/ICDAR.2003.1227801.
- [49] R. M. Pereira, D. Bertolini, L. O. Teixeira, C. N. Silla, and Y. M. G. Costa, "COVID-19 identification in chest X-ray images on flat and hierarchical classification scenarios," *Comput. Methods Programs Biomed.*, 2020, doi: 10.1016/j.cmpb.2020.105532.
- [50] X. Yang, X. He, J. Zhao, Y. Zhang & P. Xie, (2020). COVID-CT-Dataset: A CT Image Dataset about COVID-19. *arXiv preprint arXiv:2003.13865*.
- [51] A. Waheed, M. Goyal, D. Gupta, A. Khanna, F. Al-Turjman, and P. R. Pinheiro, "CovidGAN: Data Augmentation Using Auxiliary Classifier GAN for Improved Covid-19 Detection," *IEEE Access*, 2020, doi: 10.1109/ACCESS.2020.2994762.
- [52] J. Wang, & L. Perez, (2017). The effectiveness of data augmentation in image classification using deep learning. *Convolutional Neural Networks Vis. Recognit*, 11.
- [53] M. B. Jamshidi *et al.*, "Artificial Intelligence and COVID-19: Deep Learning Approaches for Diagnosis and Treatment," *IEEE Access*, 2020, doi: 10.1109/access.2020.3001973.
- [54] Z. Han *et al.*, "Accurate Screening of COVID-19 Using Attention-Based Deep 3D Multiple Instance Learning," *IEEE Trans. Med. Imaging*, 2020, doi: 10.1109/TMI.2020.2996256.
- [55] H. X. Bai *et al.*, "Performance of Radiologists in Differentiating COVID-19 from Non-COVID-19 Viral Pneumonia at Chest CT," *Radiology*, 2020, doi: 10.1148/radiol.2020200823.
- [56] N. Narayan Das, N. Kumar, M. Kaur, V. Kumar, and D. Singh, "Automated Deep Transfer Learning-Based Approach for Detection of COVID-19 Infection in Chest X-rays," *IRBM*, 2020, doi: 10.1016/j.irbm.2020.07.001.
- [57] L. Brunese, F. Mercaldo, A. Reginelli, and A. Santone, "Explainable Deep Learning for Pulmonary Disease and Coronavirus COVID-19 Detection from X-rays," *Comput. Methods Programs Biomed.*, 2020, doi: 10.1016/j.cmpb.2020.105608.
- [58] Z. Li *et al.*, "Thoracic Disease Identification and Localization with Limited Supervision," in *Advances in Computer Vision and Pattern Recognition*, 2019.
- [59] A. Sufian, A. Ghosh, A. S. Sadiq, and F. Smarandache, "A Survey on Deep Transfer Learning to Edge Computing for Mitigating the COVID-19 Pandemic: DTL-EC," *J. Syst. Archit.*, 2020, doi: 10.1016/j.sysarc.2020.101830.
- [60] T. Ozturk, M. Talo, E. A. Yildirim, U. B. Baloglu, O. Yildirim, and U. Rajendra Acharya, "Automated detection of COVID-19 cases using deep neural networks with X-ray images," *Comput. Biol. Med.*, 2020, doi: 10.1016/j.compbiomed.2020.103792.
- [61] M. Toğaçar, B. Ergen, and Z. Cömert, "COVID-19 detection using deep learning models to exploit Social Mimic Optimization and structured chest X-ray images using fuzzy color and stacking approaches," *Comput. Biol. Med.*, 2020, doi: 10.1016/j.compbiomed.2020.103805.
- [62] A. I. Khan, J. L. Shah, and M. M. Bhat, "CoroNet: A deep neural network for detection and diagnosis of COVID-19 from chest x-ray images," *Comput. Methods Programs Biomed.*, 2020, doi: 10.1016/j.cmpb.2020.105581.
- [63] T. Mahmud, M. A. Rahman, and S. A. Fattah, "CovXNet: A multi-dilation convolutional neural network for automatic COVID-19 and other pneumonia detection from chest X-ray images with transferable multi-receptive feature optimization," *Comput. Biol. Med.*, 2020, doi: 10.1016/j.compbiomed.2020.103869.
- [64] S. Minaee, R. Kafieh, M. Sonka, S. Yazdani, and G. Jamalipour Soufi, "Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning," *Med. Image Anal.*, 2020, doi: 10.1016/j.media.2020.101794.
- [65] T. B. Alakus and I. Turkoglu, "Comparison of deep learning approaches to predict COVID-19 infection," *Chaos, Solitons and Fractals*, 2020, doi: 10.1016/j.chaos.2020.110120.
- [66] H. C. Shin *et al.*, "Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning," *IEEE Trans. Med. Imaging*, 2016, doi: 10.1109/TMI.2016.2528162.
- [67] S. Roy *et al.*, "Deep Learning for Classification and Localization of COVID-19 Markers in Point-of-Care Lung Ultrasound," *IEEE Trans. Med. Imaging*, 2020, doi: 10.1109/TMI.2020.2994459.
- [68] Y. Pathak, P. K. Shukla, A. Tiwari, S. Stalin, and S. Singh, "Deep Transfer Learning Based Classification Model for COVID-19 Disease," *IRBM*, 2020, doi: 10.1016/j.irbm.2020.05.003.
- [69] X. Xu *et al.*, "A Deep Learning System to Screen Novel Coronavirus Disease 2019 Pneumonia," *Engineering*, 2020, doi: 10.1016/j.eng.2020.04.010.
- [70] A. Narin, C. Kaya, & Z. Pamuk, (2020). Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks. *arXiv preprint arXiv:2003.10849*.
- [71] L. Wang, & A. Wong, (2020). COVID-Net: A Tailored Deep Convolutional Neural Network Design for Detection of COVID-19 Cases from Chest X-Ray Images. *arXiv preprint arXiv:2003.09871*.
- [72] P. K. Sethy, S. K. Behera, P. K. Ratha, and P. Biswas, "Detection of coronavirus disease (COVID-19) based on deep features and support vector machine," *Int. J. Math. Eng. Manag. Sci.*, 2020, doi: 10.33889/IJMEMS.2020.5.4.052.



**Ernesto Cortés Pérez** recibió su grado de M. C. en Ciencias de la Computación por el Instituto Tecnológico de México, en el Laboratorio de Investigación en Tecnologías Inteligentes (LITI), Ha sido profesor en la Universidad del Istmo – Campus Tehuantepec en Oaxaca, México, en la carrera Ingeniería en Computación desde 2007, donde imparte tópicos relacionados al área de Inteligencia Artificial, sus actuales intereses incluyen Sistemas Inteligentes, Lógica Difusa, Redes Neuronales, Algoritmos Bio-inspirados, Deep Learning y Visión Artificial.



**Sergio Sánchez Sánchez** recibió su grado de Doctor por el Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE) en 2011. Desde 2014 ha sido investigador y profesor en la Universidad del Istmo en Oaxaca. Desde 2013 es parte del departamento de matemáticas aplicadas. Sus actuales intereses incluyen Óptica Cuántica, Probabilidad y Estadística Aplicada y Física Multidisciplinaria.