

The background of the cover is a deep blue color. It is decorated with a pattern of glowing light blue hexagons and interlocking gears. Some hexagons are solid, while others are outlines with small dots at their vertices. The gears are also in various shades of blue, some appearing as faint outlines and others as more prominent, semi-transparent shapes. The overall aesthetic is technical and futuristic.

Entre
CIENCIA
e
INGENIERIA

João Dallamuta
Henrique Ajuz Holzmann
(Organizadores)



Entre
CIENCIA
e
INGENIERIA

João Dallamuta
Henrique Ajuz Holzmann
(Organizadores)

Editora chefe

Profª Drª Antonella Carvalho de Oliveira

Editora executiva

Natalia Oliveira

Assistente editorial

Flávia Roberta Barão

Bibliotecária

Janaina Ramos

Projeto gráfico

Camila Alves de Cremo

Daphynny Pamplona

Gabriel Motomu Teshima

Luiza Alves Batista

Natália Sandrini de Azevedo

Imagens da capa

iStock

Edição de arte

Luiza Alves Batista

2022 by Atena Editora

Copyright © Atena Editora

Copyright do texto © 2022 Os autores

Copyright da edição © 2022 Atena Editora

Direitos para esta edição cedidos à Atena Editora pelos autores.

Open access publication by Atena Editora



Todo o conteúdo deste livro está licenciado sob uma Licença de Atribuição *Creative Commons*. Atribuição-Não-Comercial-NãoDerivativos 4.0 Internacional (CC BY-NC-ND 4.0).

O conteúdo dos artigos e seus dados em sua forma, correção e confiabilidade são de responsabilidade exclusiva dos autores, inclusive não representam necessariamente a posição oficial da Atena Editora. Permitido o *download* da obra e o compartilhamento desde que sejam atribuídos créditos aos autores, mas sem a possibilidade de alterá-la de nenhuma forma ou utilizá-la para fins comerciais.

Todos os manuscritos foram previamente submetidos à avaliação cega pelos pares, membros do Conselho Editorial desta Editora, tendo sido aprovados para a publicação com base em critérios de neutralidade e imparcialidade acadêmica.

A Atena Editora é comprometida em garantir a integridade editorial em todas as etapas do processo de publicação, evitando plágio, dados ou resultados fraudulentos e impedindo que interesses financeiros comprometam os padrões éticos da publicação. Situações suspeitas de má conduta científica serão investigadas sob o mais alto padrão de rigor acadêmico e ético.

Conselho Editorial**Ciências Exatas e da Terra e Engenharias**

Prof. Dr. Adélio Alcino Sampaio Castro Machado – Universidade do Porto

Profª Drª Alana Maria Cerqueira de Oliveira – Instituto Federal do Acre

Profª Drª Ana Grasielle Dionísio Corrêa – Universidade Presbiteriana Mackenzie

Profª Drª Ana Paula Florêncio Aires – Universidade de Trás-os-Montes e Alto Douro

Prof. Dr. Carlos Eduardo Sanches de Andrade – Universidade Federal de Goiás

Profª Drª Carmen Lúcia Voigt – Universidade Norte do Paraná



Prof. Dr. Cleiseano Emanuel da Silva Paniagua – Instituto Federal de Educação, Ciência e Tecnologia de Goiás
Prof. Dr. Douglas Gonçalves da Silva – Universidade Estadual do Sudoeste da Bahia
Prof. Dr. Eloi Rufato Junior – Universidade Tecnológica Federal do Paraná
Profª Drª Érica de Melo Azevedo – Instituto Federal do Rio de Janeiro
Prof. Dr. Fabrício Menezes Ramos – Instituto Federal do Pará
Profª Dra. Jéssica Verger Nardeli – Universidade Estadual Paulista Júlio de Mesquita Filho
Prof. Dr. Juliano Bitencourt Campos – Universidade do Extremo Sul Catarinense
Prof. Dr. Juliano Carlo Rufino de Freitas – Universidade Federal de Campina Grande
Profª Drª Luciana do Nascimento Mendes – Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte
Prof. Dr. Marcelo Marques – Universidade Estadual de Maringá
Prof. Dr. Marco Aurélio Kistemann Junior – Universidade Federal de Juiz de Fora
Prof. Dr. Miguel Adriano Inácio – Instituto Nacional de Pesquisas Espaciais
Profª Drª Neiva Maria de Almeida – Universidade Federal da Paraíba
Profª Drª Natiéli Piovesan – Instituto Federal do Rio Grande do Norte
Profª Drª Priscila Tessmer Scaglioni – Universidade Federal de Pelotas
Prof. Dr. Sidney Gonçalo de Lima – Universidade Federal do Piauí
Prof. Dr. Takeshy Tachizawa – Faculdade de Campo Limpo Paulista



Diagramação: Daphynny Pamplona
Correção: Maiara Ferreira
Indexação: Amanda Kelly da Costa Veiga
Revisão: Os autores
Organizadores: João Dallamuta
Henrique Ajuz Holzmann

Dados Internacionais de Catalogação na Publicação (CIP)

E61 Entre ciencia e ingenieria / Organizadores João Dallamuta, Henrique Ajuz Holzmann. – Ponta Grossa - PR: Atena, 2022.

Formato: PDF
Requisitos de sistema: Adobe Acrobat Reader
Modo de acesso: World Wide Web
Inclui bibliografia
ISBN 978-65-258-0040-0
DOI: <https://doi.org/10.22533/at.ed.400222903>

1. Ciências aplicadas. 2. Engenharia. I. Dallamuta, João (Organizador). II. Holzmann, Henrique Ajuz (Organizador). III. Título.

CDD 601

Elaborado por Bibliotecária Janaina Ramos – CRB-8/9166

Atena Editora
Ponta Grossa – Paraná – Brasil
Telefone: +55 (42) 3323-5493
www.atenaeditora.com.br
contato@atenaeditora.com.br



DECLARAÇÃO DOS AUTORES

Os autores desta obra: 1. Atestam não possuir qualquer interesse comercial que constitua um conflito de interesses em relação ao artigo científico publicado; 2. Declaram que participaram ativamente da construção dos respectivos manuscritos, preferencialmente na: a) Concepção do estudo, e/ou aquisição de dados, e/ou análise e interpretação de dados; b) Elaboração do artigo ou revisão com vistas a tornar o material intelectualmente relevante; c) Aprovação final do manuscrito para submissão.; 3. Certificam que os artigos científicos publicados estão completamente isentos de dados e/ou resultados fraudulentos; 4. Confirmam a citação e a referência correta de todos os dados e de interpretações de dados de outras pesquisas; 5. Reconhecem terem informado todas as fontes de financiamento recebidas para a consecução da pesquisa; 6. Autorizam a edição da obra, que incluem os registros de ficha catalográfica, ISBN, DOI e demais indexadores, projeto visual e criação de capa, diagramação de miolo, assim como lançamento e divulgação da mesma conforme critérios da Atena Editora.



DECLARAÇÃO DA EDITORA

A Atena Editora declara, para os devidos fins de direito, que: 1. A presente publicação constitui apenas transferência temporária dos direitos autorais, direito sobre a publicação, inclusive não constitui responsabilidade solidária na criação dos manuscritos publicados, nos termos previstos na Lei sobre direitos autorais (Lei 9610/98), no art. 184 do Código Penal e no art. 927 do Código Civil; 2. Autoriza e incentiva os autores a assinarem contratos com repositórios institucionais, com fins exclusivos de divulgação da obra, desde que com o devido reconhecimento de autoria e edição e sem qualquer finalidade comercial; 3. Todos os e-book são *open access*, *desta forma* não os comercializa em seu site, sites parceiros, plataformas de *e-commerce*, ou qualquer outro meio virtual ou físico, portanto, está isenta de repasses de direitos autorais aos autores; 4. Todos os membros do conselho editorial são doutores e vinculados a instituições de ensino superior públicas, conforme recomendação da CAPES para obtenção do Qualis livro; 5. Não cede, comercializa ou autoriza a utilização dos nomes e e-mails dos autores, bem como nenhum outro dado dos mesmos, para qualquer finalidade que não o escopo da divulgação desta obra.



APRESENTAÇÃO






A palavra ciência vem do latim *scientia*, que significa conhecimento. Nos primórdios essa palavra (e sua origem latina) tinha o mesmo tipo de significado dado à filosofia, no sentido mais amplo do termo. Modernamente, por ciência entendemos um sistema de conhecimento obtido através de uma atividade de pesquisa organizada principalmente com procedimentos metódicos e rigorosos, combinando experimentação com raciocínio lógico baseado em um conjunto de axiomas. Seu objetivo é chegar a uma descrição provável, com caráter preditivo, da realidade e das leis que regulam o aparecimento dos fenômenos.

Já a engenharia é o uso de princípios científicos para projetar e construir máquinas, estruturas e outras entidades, incluindo pontes, túneis, estradas, veículos, edifícios, sistemas e processos. Aproveitar o acúmulo de conhecimento tecnológico para inovação, invenção, desenvolvimento e aprimoramento de técnicas e ferramentas para atender às necessidades e solucionar problemas técnicos das pessoas e da sociedade. O engenheiro se apoia nas ciências básicas (matemática, física, química, biologia, ciências econômicas e administrativas, ciências da engenharia, engenharia aplicada) tanto para o desenvolvimento de tecnologias, quanto para a gestão eficiente e produtiva dos recursos e forças da natureza para benefício da sociedade. A engenharia é uma atividade que transforma o conhecimento em algo prático.

Engenharia e Ciência caminham lado a lado pelo progresso da humanidade. É impossível dissociá-las. Neste livro temos uma diversidade de temas, níveis de profundidade e abordagens de pesquisa, envolvendo aspectos técnicos e científicos. Aos autores e editores, agradecemos pela confiança e espírito de parceria.

João Dallamuta
Henrique Ajuz Holzmann

SUMÁRIO

CAPÍTULO 1	1
ESTIMACIÓN DE PARÁMETROS DE COLE EN TEJIDO TUMORAL: ESTUDIO IN-VIVO	
Nataly Patricia López Saquisilí	
Daniela Campo	
César Antonio Gonzáles Díaz	
 https://doi.org/10.22533/at.ed.4002229031	
CAPÍTULO 2	9
ALGORITMOS DE DEEP LEARNING PARA LA DETECCIÓN DE NEUMONÍA EN INFANTES A TRAVÉS DE IMÁGENES DE RADIOGRAFÍAS DEL TÓRAX	
Juan Carlos Valero Gómez	
Alex Peter Zúñiga Incalla	
Juan Carlos Clares Perca	
Diego Ismael Mamani Padilla	
 https://doi.org/10.22533/at.ed.4002229032	
CAPÍTULO 3	21
AUTOMATIZACIÓN Y MONITOREO DE PARÁMETROS EN UN INVERNADERO	
Miguel Ángel Barrera Valdés	
Juan Barrera Valdés	
Julián Omar Baltazar Hernández	
José Rebrindanard Rubalcava López	
 https://doi.org/10.22533/at.ed.4002229033	
CAPÍTULO 4	26
EL ANÁLISIS DE CASO UNA METODOLOGÍA DE APRENDIZAJE INTEGRADA CON LA GAMIFICACIÓN CASO APLICACIÓN MÓDULO ESTRATEGIA DE CONTROL DE GESTIÓN Y KIMEM PM	
Marcia Ricardina Silva Flores	
Jaime Orellana Rebolledo	
Paula Vergara Harris	
 https://doi.org/10.22533/at.ed.4002229034	
CAPÍTULO 5	41
LA INNOVACIÓN SOCIAL EN EL MARCO DEL DESARROLLO URBANO SOSTENIBLE: EVALUACIÓN DEL PROYECTO TROPA VERDE EN SANTIAGO DE COMPOSTELA	
Matías Pino	
 https://doi.org/10.22533/at.ed.4002229035	
CAPÍTULO 6	57
LA GESTIÓN DEL RIESGO DE INUNDACIÓN EN EL AULA: UNA PROPUESTA BASADA EN LA INDAGACIÓN	
José Ramón Díez	
Claudia Pichot	
Unai Ortega-Lasuen	
 https://doi.org/10.22533/at.ed.4002229036	
SOBRE OS ORGANIZADORES	70
ÍNDICE REMISSIVO	71

CAPÍTULO 2

ALGORITMOS DE DEEP LEARNING PARA LA DETECCIÓN DE NEUMONÍA EN INFANTES A TRAVÉS DE IMÁGENES DE RADIOGRAFÍAS DEL TÓRAX

Data de aceite: 01/02/2022

Fecha de envío: 03/12/2021

Juan Carlos Valero Gómez

Universidad Nacional de Moquegua, Ilo, Perú
<https://orcid.org/0000-0002-7077-7531>

Alex Peter Zúñiga Incalla

Universidad Nacional de Moquegua, Ilo, Perú
<https://orcid.org/0000-0003-4734-2262>

Juan Carlos Clares Perca

Universidad Nacional de Moquegua, Ilo, Perú
<https://orcid.org/0000-0001-5146-2879>

Diego Ismael Mamani Padilla

Universidad Nacional de Moquegua, Ilo, Perú
<https://orcid.org/0000-0001-7517-5823>

RESUMEN: Una gran cantidad de infantes fallecen cada año a consecuencia de la neumonía en todo el mundo. Se reporta que aproximadamente más de 1 millón de casos de neumonía en infantes se da entre 0 y 5 años de edad, de los cuales 808 694 murieron en 2017. Por ende, la neumonía es una de las principales causas de fallecimiento entre los infantes, con un alto nivel de mortalidad en Asia y África. Incluso en un país desarrollado como Estados Unidos, la neumonía se encuentra entre las 10 principales causas de muerte. La detección y el tratamiento tempranos de la neumonía pueden reducir significativamente las tasas de mortalidad entre los infantes en países emergentes. Por lo tanto, este trabajo presenta algoritmos de deep learning

para detectar neumonía mediante imágenes de radiográficas. Se entrenaron tres algoritmos de deep learning para clasificar las imágenes de radiografías en dos clases: neumonía y normal. Se presentan tres algoritmos, a cada uno se añadió una capa *pooling* de 4x4, se vectoriza los datos con la técnica *flatten*, se agregaron seis capas dense de 1024, 512, 256, 128, 64 y 32 de valor de salida y cada una con *activación relu*; se aplica un *BatchNormalization*, finalmente se agrega una capa dense de 2 con una activación *softmax* para la clasificación. Los tres algoritmos son modelos previamente entrenados, que son Xception, MobileNet e InceptionV3 obtuvieron en la métrica de accuracy 94.4%, 96.2% y 95.3% respectivamente.

PALABRAS-CLAVE: Neumonía infantil, deep learning, Xception, MobileNet, InceptionV3.

DEEP LEARNING ALGORITHMS FOR THE DETECTION OF PNEUMONIA IN INFANTS THROUGH CHEST X-RAY IMAGES

ABSTRACT: Worldwide, large numbers of infants die of pneumonia each year. It is reported that approximately more than 1 million cases of pneumonia in infants occur between 0 and 5 years of age, of which 920 136 died in 2015. Therefore, pneumonia is one of the leading causes of death among infants, with a high level of mortality in Asia and Africa. Even in a developed country like the United States, pneumonia is among the top 10 causes of death. Early detection and treatment of pneumonia can significantly reduce mortality rates among infants in emerging countries. Therefore, this work presents deep learning algorithms to

detect pneumonia using radiographic images. Three deep learning algorithms were trained to classify X-ray images into two classes: pneumonia and normal. Three algorithms are presented, to each one a 4x4 pooling layer was added, the data is vectorized with the flatten technique, six dense layers of 1024, 512, 256, 128, 64 and 32 of output value were added and each one with relu activation; A BatchNormalization is applied, finally a dense layer of 2 is added with a softmax activation for classification. The three algorithms are previously trained models, which are Xception, MobileNet and InceptionV3 obtained in the accuracy metric 94.4%, 96.2% and 95.3% respectively.

KEYWORDS: childhood pneumonia, deep learning, Xception, MobileNet, InceptionV3.

1 | INTRODUCCIÓN

La neumonía es una infección aguda respiratoria que ataca a los pulmones. La neumonía es la principal causa individual de mortalidad infantil en todo el mundo. Se calcula que la neumonía mató a unos 808 694 infantes menores de 5 años en 2017, lo que supone el 15% de todas los fallecimientos de infantes menores de 5 años a nivel mundial (OMS, 2019). En los países emergentes hay una escasa disponibilidad de profesionales médicos y radiólogos que cumplen un papel fundamental en el diagnóstico de la neumonía (LIU *et al.*, 2018). En la última década se ha empleado para el diagnóstico de enfermedades la asistencia por computadora basado en algoritmos de inteligencia artificial, estas tecnologías se pueden poner a disposición de una gran población a un costo mínimo. Un problema recurrente en la detección de enfermedades pulmonares es que, a veces, los patrones característicos de una enfermedad tienen algún grado de similitud con otras enfermedades, ocasionando que los médicos especializados tengan dificultades en realizar un diagnóstico preciso.

Entre las técnicas de deep learning (aprendizaje profundo), las redes neuronales convolucionales han demostrado ser eficientes en la clasificación de imágenes, son frecuentemente utilizadas por los investigadores para la visión computacional. Estas técnicas han demostrado ser útiles al reconocimiento rápidos y preciso de la neumonía que se equiparan o superan a un especialista médico. No obstante, las técnicas de deep learning no pueden sustituir a los médicos especialistas para realizar un diagnóstico, sino es una herramienta más para el personal médico en la toma de decisiones clínicas (KALLIANOS *et al.*, 2019).

El presente trabajo emplea tres modelos basados en algoritmos de deep learning que son capaces de detectar automáticamente si un paciente padece de neumonía o no. En ese sentido, se plantea desarrollar tres algoritmos de deep learning que puedan superar las expectativas de la investigación, para ellos se empleará algoritmos pre-entrenados y se importará los pesos de ImageNet para lograr un mejor desempeño (DENG *et al.*, 2014). Los resultados serán evaluados a través de métricas que determinarán si los algoritmos propuestos tienen resultados óptimos.

2 | METODOLOGÍA

2.1 Dataset

En el presente trabajo se empleó un dataset publicado en la comunidad de ciencias de datos KAGGLE por KERMANY *et al.* (2018), el dataset cuenta con un total de 5856 imágenes de radiografías del tórax de infantes anonimizados. El dataset cuenta con dos clases, pacientes con neumonía con un total de 4273 imágenes y pacientes sanos con un total de 1583 imágenes, como se puede visualizar en la Figura 1, el dataset se encuentra desbalanceado; no obstante, se cuenta con un numero aceptable en pacientes sanos para la experimentación, en los resultados se podrá determinar el nivel de incidencia del desbalance en las métricas de evaluación.




Figura 1: Distribución del Dataset.

Fuente: Elaboración propia.

El dataset se dividió en dos conjuntos, el conjunto de entrenamiento con el 80%, siendo 4696 imágenes, conformado por 3458 imágenes de pacientes con neumonía y 1238 imágenes de pacientes sanos; y el conjunto de test con el 20% del total, siendo 1160 imágenes, el conjunto de test está conformado por 815 imágenes de pacientes con neumonía y 345 imágenes de pacientes sanos.




Figura 2: Distribución del Dataset.

Fuente: Elaboración propia.

Los datos del entrenamiento se dividen nuevamente en datos para entrenar y datos para la validación, en este caso del total de los datos de entrenamiento un 20% se destinará para la validación cruzada, está conformado por 692 imágenes de pacientes con neumonía y 248 imágenes de pacientes sanos. Se puede ver una muestra en la Figura 2.

Cada imagen del dataset han sido pre-procesadas normalizándolas y puedan ser empleadas en el entrenamiento de los algoritmos. Se reescaló cada imagen a una resolución de 256x256 píxeles, esta resolución es aceptada por los tres algoritmos como valores de entrada, Además, cada pixel tiene un valor que se encuentra entre el rango de $[0, 255]$, el valor del pixel ha sido convertido para que esté dentro del rango de $[0, 1]$, esta conversión tiene como objetivo facilitar las operaciones matriciales.

2.2 Algoritmos

Se emplearon tres algoritmos de deep learning para el estudio, InceptionV3 (SZEGEDY *et al.*, 2016), MobileNet (HOWARD *et al.*, 2019) y Xception (CHOLLET, 2017). Para hacer uso de los algoritmos propuestos se utilizó la librería de Tensorflow y Keras. Para recortar los tiempos de entrenamiento de los algoritmos y una mejor eficacia de los mismo se utilizó la técnica de Transfer Learning con ImageNet (DENG *et al.*, 2014). El hecho de usar la misma arquitectura con los mismos parámetros que el modelo pre-entrenado, otorgará a los algoritmos la capacidad de reconocer varias clases desde el comienzo, lo que además se traducirá en un tiempo de entrenamiento muy reducido. Para tener la capacidad de computo necesaria para ejecutar los algoritmos InceptionV3, MobileNet y Xception se empleó la plataforma de Google Colab que proporciona el uso de GPU's necesarios para la experimentación.

A la arquitectura del algoritmo Xception se ha adicionado una capa pooling de 4x4, se vectoriza los datos con la técnica flatten, se agregaron seis capas dense de 1024, 512, 256, 128 64 y 32 de valor de salida y cada una con activación relu; se aplica un BatchNormalization, finalmente se agrega una capa dense de 2 con una activación softmax

para la clasificación.

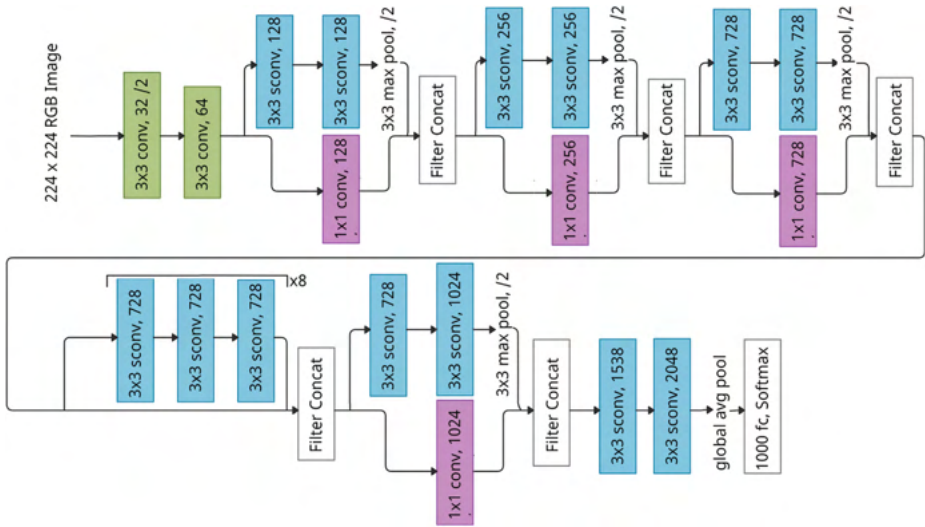


Figura 3: Arquitectura de Xception.

Fuente: www.techscience.com.

A la arquitectura del algoritmo MobileNet se ha adicionado una capa pooling de 4x4, se vectoriza los datos con la técnica flatten, se agregaron seis capas dense de 1024, 512, 256, 128, 64 y 32 de valor de salida y cada una con activación relu; se aplica un BatchNormalization, finalmente se agrega una capa dense de 2 con una activación softmax para la clasificación.




Figura 4: Arquitectura de MobileNet.

Fuente: Elaboración propia.

A la arquitectura del algoritmo InceptionV3 se ha adicionado una capa pooling de

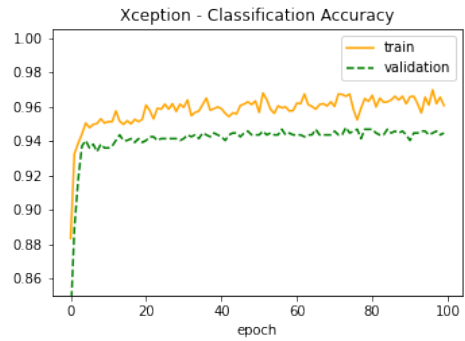



Figura 6: Evaluación del desempeño en la etapa de entrenamiento y validación de las métricas de precisión y la entropía cruzada para Xception.

Fuente: Elaboración propia.

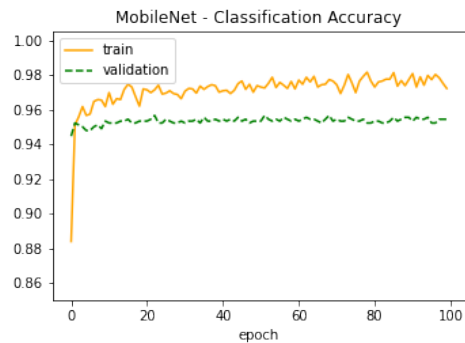
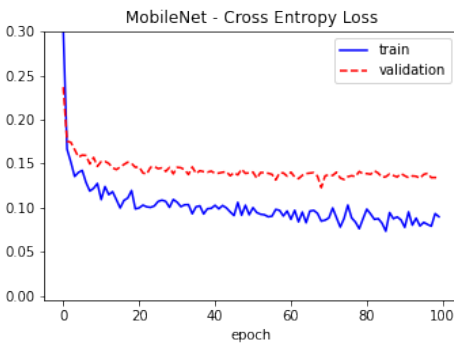


Figura 7: Evaluación del desempeño en la etapa de entrenamiento y validación de las métricas de precisión y la entropía cruzada para MobileNet.

Fuente: Elaboración propia.

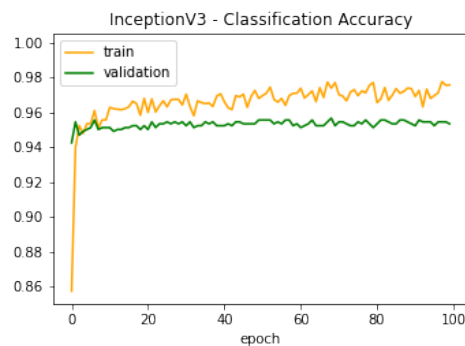
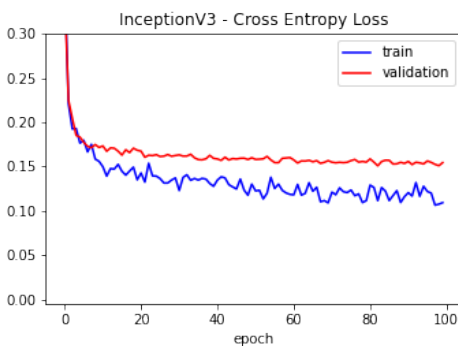


Figura 8: Evaluación del desempeño en la etapa de entrenamiento y validación de las métricas de precisión y la entropía cruzada para InceptionV3.

Fuente: Elaboración propia.

Para la etapa de test se separó 1160 imágenes, a este grupo de datos se aplicó el método *predict* que otorgó una estimación para cada clase, la estimación estará en el rango de 0 a 1, posteriormente se aplicará el método *argmax* para que devuelva la clase con mayor estimación. De este modo, solo tendremos 0 (normal) y 1 (neumonía).




Figura 9: Matriz de Confusión para los resultados con Xception donde 0 = Normal y 1 = Neumonía.

Fuente: Elaboración propia.

En la Figura 9, se visualiza los resultados de la Matriz de Confusión para Xception, acierta correctamente 304 y 791 veces para Normal y Neumonía respectivamente. No obstante, también obtiene 26 falsos positivos y 39 falsos negativos; es decir, 26 veces predijo que era Normal cuando realmente era Neumonía, y 39 veces predijo que era Neumonía cuando era Normal.




Figura 10: Matriz de Confusión para los resultados con MobileNet, donde 0 = Normal y 1 = Neumonía.

Fuente: Elaboración propia.

En la Figura 10, se visualiza los resultados de la Matriz de Confusión para MobileNet, acierta correctamente 330 y 786 veces para Normal y Neumonía respectivamente. No obstante, también obtiene 29 falsos positivos y 15 falsos negativos; es decir, 29 veces predijo que era Normal cuando realmente era Neumonía, y 15 veces predijo que era Neumonía cuando era Normal.




Figura 11: Matriz de Confusión para los resultados con InceptionV3, donde 0 = Normal y 1 = Neumonía

Fuente: Elaboración propia.

En la Figura 11, se visualiza los resultados de la Matriz de Confusión para InceptionV3, acierta correctamente 279 y 826 veces para Normal y Neumonía respectivamente. No obstante, también obtiene 26 falsos positivos y 29 falsos negativos; es decir, 26 veces predijo que era Normal cuando realmente era Neumonía, y 29 veces predijo que era Neumonía cuando era Normal.

Algoritmo	Clase	Accuracy	Precision	Recall	F1-Score
Xception	Normal	0.944	0.92	0.89	0.90
	Neumonía		0.95	0.97	0.96
MobileNet	Normal	0.962	0.92	0.96	0.94
	Neumonía		0.98	0.96	0.97
InceptionV3	Normal	0.953	0.91	0.91	0.91
	Neumonía		0.97	0.97	0.97

Tabla 1: Métricas de evaluación para cada algoritmo.

Fuente: Elaboración propia.

A partir de la Matriz de Confusión podemos calcular las métricas de accuracy, precisión, recall y F1-score de cada algoritmo empleado para el presente estudio. Los resultados podemos verlos en la Tabla 1, cada algoritmo ha demostrado un alto desempeño, pero MobileNet ha obtenido mejores resultados para cada métrica, le sigue InceptionV3 que por poco margen dista de los resultados obtenidos por MobileNet, el caso de Xception obtuvo resultados por debajo de InceptionV3 y MobileNet, esto debido a que sufrió de un sobreajuste más pronunciado en la etapa de entrenamiento como se puede visualizar en la Figura 3.

4 | DISCUSIÓN

Los resultados obtenidos son más que aceptables en comparación a otras investigaciones realizadas sobre el mismo dataset, en la investigación de LIANG & ZHENG (2020) experimentaron con VGG16, DenseNet121, InceptionV3, Xception y un modelo propuestos por ellos, el modelo que mejor resultados les proporciono fue el modelo que proponen obteniendo un accuracy de 90.50%, en Xception obtuvieron 87.80% de accuracy e InceptionV3 obtuvieron un 85.30% de accuracy. Mientras en la presente investigación se obtuvo con MobileNet un 96.20% de accuracy, InceptionV3 obtuvo 95.30% y Xception obtuvo un 94.40%, esta mejora significativa a comparación de los resultados obtenidos por LIANG & ZHENG (2020) es debido a la profundidad con las seis capas densas que se añadió a los tres modelos empleados en la investigación, al poder extraer y mapear las características de cada imagen del dataset los modelos han podido generalizar adecuadamente, esto se demuestra con los resultados obtenidos.

5 | CONCLUSIONES

En este trabajo, se presentaron tres algoritmos diferentes pre-entrenados para la aplicación en la detección de neumonía. Los algoritmos fueron Xception, MobileNet e InceptionV3 que obtuvieron resultados más que aceptables. Xception obtuvo un 94.4% en la métrica de accuracy, 93.5% en la métrica de precision, 93.0% en la métrica de recall, 93.0% en la métrica de F1-score. MobileNet obtuvo un 96.2% en la métrica de accuracy, 95.0% en la métrica de precision, 96.0% en la métrica de recall, 95.5% en la métrica de F1-score. Por último, InceptionV3 obtuvo un 95.3% en la métrica de accuracy, 94.0% en la métrica de precision, 94.0% en la métrica de recall, 94.0% en la métrica de F1-score. De los resultados podemos concluir que MobileNet ha demostrado un mejor desempeño ante Xception e InceptionV3, en las diferentes métricas empleadas. Además, su complejidad es muy inferior a los otros algoritmos con 8.1 millones de parámetros, conllevando a la utilización de menos recursos computacionales. Los resultados indican que MobileNet cuenta con un nivel muy alto de eficiencia en relación a Xception e InceptionV3.

REFERENCIAS

CHOLLET, François. Xception: Deep learning with depthwise separable convolutions. **Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017**, [s. l.], v. 2017-Janua, p. 1800–1807, 2017. Disponible em: <https://doi.org/10.1109/CVPR.2017.195>.

DENG, Jia *et al.* Scalable Multi-label Annotation. [s. l.], p. 1–4, 2014.

HOWARD, Andrew *et al.* Searching for MobileNetV3 Accuracy vs MADDs vs model size. **International Conference on Computer Vision**, [s. l.], p. 1314–1324, 2019.

KALLIANOS, K. *et al.* How far have we come? Artificial intelligence for chest radiograph interpretation. **Clinical Radiology**, [s. l.], v. 74, n. 5, p. 338–345, 2019. Disponible em: <https://doi.org/10.1016/j.crad.2018.12.015>.

KERMANY, Daniel S. *et al.* Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning. **Cell**, [s. l.], v. 172, n. 5, p. 1122–1131.e9, 2018. Disponible em: <https://doi.org/10.1016/j.cell.2018.02.010>.

LIANG, Gaobo; ZHENG, Lixin. Computer Methods and Programs in Biomedicine A transfer learning method with deep residual network for pediatric. **Computer Methods and Programs in Biomedicine**, [s. l.], n. xxxx, 2019. Disponible em: <https://doi.org/10.1016/j.cmpb.2019.06.023>.

LIU, Na *et al.* Exploiting Convolutional Neural Networks With Deeply Local Description for Remote Sensing Image Classification. **IEEE Access**, [s. l.], v. 6, n. c, p. 11215–11227, 2018. Disponible em: <https://doi.org/10.1109/ACCESS.2018.2798799>.

OMS. **Pneumonia**. [S. l.], 2019. Disponible em: <https://www.who.int/es/news-room/fact-sheets/detail/pneumonia>.

SONG, Shuang; CHAUDHURI, Kamalika; SARWATE, Anand D. Stochastic gradient descent with differentially private updates. **2013 IEEE Global Conference on Signal and Information Processing, GlobalSIP 2013 - Proceedings**, [s. l.], n. December 2013, p. 245–248, 2013. Disponível em: <https://doi.org/10.1109/GlobalSIP.2013.6736861>.

SZEGEDY, Christian *et al.* Rethinking the Inception Architecture for Computer Vision. **Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition**, [s. l.], v. 2016-Decem, p. 2818–2826, 2016. Disponível em: <https://doi.org/10.1109/CVPR.2016.308>

ÍNDICE REMISSIVO

A

Android 21, 22, 23, 25

Aula 3, 30, 57, 62, 64, 68

B

Bioimpedancia 1, 2, 4, 5, 7

C

Capacitación 24, 57, 58

Cole 1, 2, 3, 4, 5, 7, 8

COLE 3, 1

Cultivos 21

CULTIVOS 21, 24

D

Deep learning 3, 9, 10, 12, 19

E

Estrategias metodológicas 26, 30, 31

G

Gamificación 34

GAMIFICACIÓN 3, 26, 30, 31, 32, 34, 39, 40

Gestión riesgo inundación 57

I

Indagación 3, 57, 59, 62, 63, 68

Innovación social 3, 41, 42, 43, 44, 45, 46, 47, 48, 49, 51, 54, 55, 56

Invernadero 21, 24

INVERNADERO 3, 21, 22, 24

N

Neumonía infantil 9

P

Parámetros 7, 21

PARÁMETROS 3, 1, 2, 3, 4, 5, 7, 12, 19, 21, 24

Participación ciudadana 41, 52

Proyectos 33

PROYECTOS 26, 31, 33, 36

R

Resultados de aprendizaje 26, 30, 31

S

Secuencia didáctica 5, 26, 31, 38, 57, 64

Sostenibilidad urbana 41, 43, 53, 54

T

Tejido 1, 8

TEJIDO 3, 1, 2, 3, 4, 5

Tumor 1, 7

TUMOR 1

X

Xception 9, 10, 12, 13, 14, 15, 16, 18, 19






Entre
CIENCIA
e
INGENIERIA

 www.atenaeditora.com.br
 contato@atenaeditora.com.br
 [@atenaeditora](https://www.instagram.com/atenaeditora)
 www.facebook.com/atenaeditora.com.br



Entre
CIENCIA
e
INGENIERIA

-  www.atenaeditora.com.br
-  contato@atenaeditora.com.br
-  [@atenaeditora](https://www.instagram.com/atenaeditora)
-  www.facebook.com/atenaeditora.com.br