

E-FFireNet: Transferencia de Aprendizaje Eficiente para Clasificación de Incendios Forestales

E-FFireNet: Efficient Transfer Learning to Forest Fire Classification

1st Stalin Edgar Pacoricona Quispe
Escuela Profesional de Ingeniería de Sistemas
Universidad Andina Néstor Cáceres Velásquez
Juliaca, Perú
ORCID: 0009-0006-2437-827X

2nd Luizinho Benjamin Huanca Zucso
Escuela Profesional de Ingeniería de Sistemas
Universidad Andina Néstor Cáceres Velásquez
Juliaca, Perú
ORCID: 0009-0002-7961-9924

3rd Lenin Gabriel Machaca Calla
Escuela Profesional de Ingeniería de Sistemas
Universidad Andina Néstor Cáceres Velásquez
Juliaca, Perú
ORCID: 0009-0000-3878-5833

4th Liz Maribel Huancapaza Hilasaca
Escuela Profesional de Ingeniería de Sistemas
Universidad Andina Néstor Cáceres Velásquez
Juliaca, Perú
ORCID: 0000-0002-0345-2075

5th Ivar Vargas Belizario
Escuela Profesional de Ingeniería de Sistemas
Universidad Andina Néstor Cáceres Velásquez
Juliaca, Perú
ORCID: 0000-0001-5970-2283

Resumen—La importancia de la clasificación de incendios forestales mediante métodos computacionales radica en su aplicabilidad en la detección temprana y alerta oportuna para evitar su propagación. Según el estado de arte, la clasificación de incendios forestales fue abordado por propuestas basadas en aprendizaje máquina (ML) y aprendizaje profundo (DL), más específicamente en Redes Neurales Convolucionales (CNN). En la práctica, los métodos basados en DL se muestran superiores a los métodos tradicionales de ML. Recientemente, fue propuesto FFireNet, un modelo CNN que presenta resultados óptimos para clasificar imágenes de incendios forestales. Sobre esta base en este trabajo, presentamos una metodología para crear modelos CNN por *transfer learning* aplicado específicamente a la clasificación de incendios forestales, donde fueron incluidas técnicas como *data augmentation*, *transfer learning* y *fine tuning*. La propuesta permitió definir E-FFireNet, un modelo eficiente con resultados superiores a FFireNet. Los experimentos mostraron resultados de clasificación de 99,73 (*accuracy*), 99,48 (*precision*), 100,0 (*recall*) y 0,263 (*error*).

Palabras clave—*Transferencia de aprendizaje, aumento de datos, clasificación de incendios forestales.*

Abstract—The importance of the classification of forest fires through computational methods lies in their applicability for early detection and timely warning to prevent their spread. According to the state of the art, the classification of forest fires was approached by proposals based on machine learning (ML) and deep learning (DL), more specifically on Convolutional Neural Networks (CNN). In practice, DL-based methods prove

to be superior to traditional ML methods. Recently, FFireNet, a CNN model that presents optimal results for classifying images of forest fires, was proposed. On this basis, in this work, we present a methodology to create CNN models by transfer learning applied specifically to the classification of forest fires, where techniques such as data augmentation, transfer learning, transfer learning and fine tuning were included. The proposal allowed us to define E-FFireNet, an efficient model with superior results than FFireNet. The experiments showed classification results of 99,73 (*accuracy*), 99,48 (*precision*), 100,0 (*recall*) and 0,263 (*error*).

Keywords—*Transfer learning, data augmentation, forest fire classification.*

I. INTRODUCCIÓN

Los bosques son la vitalidad del mundo [1]. Un incendio forestal puede afectar la vida silvestre, los árboles y a cualquier otro tipo de vegetación, estos daños causados pueden ser físicos o hacerlas susceptibles al ataque de diversos patógenos. Un incendio no solo podría afectar los árboles sino también las propiedades biológicas del suelo donde ocurre, en consecuencia, el suelo se vuelve inadecuado para el crecimiento de la vegetación [2], es decir, el daño que causan los incendios a la economía forestal es mayor que todos los daños causados por otros factores. Los casos de incendios forestales están en constante aumento, debido a diversos factores (altas temperaturas, clima seco, etc) [3]. Un antecedente reciente

sería el devastador incendio en Australia en el año 2020, donde se quemaron alrededor de 19 millones de hectáreas de tierras forestales, la muerte de medio millón de animales de varias especies, la pérdida de 33 vidas humanas y miles de hospitalizaciones [4]. Con el propósito de proteger los bosques de los incendios, los gobiernos desarrollan estrategias de vigilancia y detección inteligente de incendios forestales, utilizando tecnologías como sensores. Estos dispositivos junto a los vehículos aéreos no tripulados permiten coleccionar gran cantidad de datos que pueden ser procesados y analizados aplicando diversas técnicas y estrategias de inteligencia artificial (IA) [1].

La clasificación de los incendios forestales fue abordado con métodos tradicionales de Aprendizaje Máquina (ML) [5], donde inicialmente son empleados descriptores para extraer características. Luego, modelos de aprendizaje supervisado son entrenados sobre las características extraídas. Por otra parte, también existen nuevas propuestas basadas en Aprendizaje Profundo (DL) [6], [7], donde redes neuronales convolucionales (CNN) son entrenadas para determinar pesos eficientes que conlleven a realizar tareas de clasificación, en este tipo de propuestas la extracción de características no es necesaria, en realidad se realiza al mismo tiempo que se determina los mejores pesos para las redes neuronales profundas. En ambos tipos de propuestas (ML y DL) el desafío es desarrollar métodos automáticos para la clasificación y detección temprana de incendios forestales.

En este trabajo presentamos un método para crear modelos CNN empleando *transfer learning* con aplicación al dominio específico de clasificación de incendios forestales. Las principales contribuciones alcanzadas en este trabajo son presentadas a continuación:

- Propuesta de una metodología (E-FFireNet) para crear modelos de CNN por *transfer learning* aplicado a la clasificación de incendios forestales.
- Inclusión de dos algoritmos de procesamiento de imágenes para ser utilizadas como técnicas de *data augmentation*.
- Aplicación del método propuesto sobre 5 modelos de CNN preentrenados para tareas de clasificación de incendios forestales.
- Evaluación del método propuesto (E-FFireNet) para verificar la robustez y eficiencia en comparación con el mejor método de la literatura actual, FFireNet.

II. TRABAJOS RELACIONADOS

Recientemente, fue propuesto FFireNet [6] para la clasificación y detección de incendios forestales en ciudades inteligentes. FFireNet fue desarrollado en base al modelo preentrenado de MobileNetV2 [8]. Donde fue necesario incluir capas completamente conectadas para resolver el problema de reconocimiento de imágenes que tienen fuego y que permita la clasificación de imágenes de incendios forestales. FFireNet fue evaluado con diferentes métricas de rendimiento y fue comparado con otros modelos de CNN. Los resultados mostraron

que el modelo propuesto logró 98,42 (*accuracy*), 1,58 (*error*), 99,47 (*recall*) y 97,42 (*precision*).

Otro trabajo fue propuesto para clasificar imágenes que incluyen fuego y humo [7], donde se incluyen 3 clases: imágenes con fuego, imágenes con humo y otras imágenes naturales que no incluyen las 2 primeras clases. En ese trabajo fueron comparados modelos tradicionales de aprendizaje máquina con modelos de aprendizaje profundo, CNN. Para modelos tradicionales, primero fueron extraídas características basadas en color, contorno y textura. Después, fueron entrenados modelos como *Decision Tree*, *K-Nearest Neighbor* (KNN), *Random Forest* (RF) y SVM. Por último, un modelo CNN fue configurado con 2 capas de 32 y 64 filtros de convolución, respectivamente. Los resultados demostraron la superioridad del modelo CNN con un resultado de clasificación (*accuracy*) de 96,0.

Existe otro trabajo para clasificar imágenes de incendios forestales que fusiona características de color y de textura de las imágenes [5]. Primero, utilizando el espacio de color GRB-YCbCr las imágenes son segmentadas para extraer la región con mayor sospecha de contener fuego. Luego, sobre la región segmentada son extraídas 10 características de textura mediante el descriptor *Local Binary Pattern* (LBP) y 4 características de textura utilizando el descriptor *Gray Level Co-occurrence Matrix* (GLCM). Después, para clasificar las imágenes, fue entrenando un modelo de aprendizaje supervisado basado en el modelo *Support Vector Machine* (SVM). Los resultados mostraron que la tasa de clasificación del método para incendios forestales alcanzó el 93,15.

III. MATERIALES Y MÉTODOS

La Figura 1 ilustra las etapas del método propuesto denominado como E-FFireNet. Dado un conjunto de imágenes de incendios forestales que presentan 2 clases (Sección III-A), primero son creadas imágenes utilizando técnicas de *data augmentation* basadas en algoritmos de procesamiento de imágenes (Sección III-B). Luego, CNNs preentrenadas son adaptadas por *transfer learning* para ejecutar tareas de clasificación binaria (Sección III-C). Después, el modelo adaptado es reentrenado incluyendo técnicas de *fine tuning* (Sección III-D). Finalmente, el aprendizaje de los modelos es evaluado por la predicción de imágenes que no fueron incluidas en el entrenamiento (Sección III-E). A continuación son descritas en detalle cada una de estas etapas.

III-A. Conjunto de datos

El conjunto de datos DS1 [1] consiste de imágenes de escenas naturales que incluyen 2 clases: imágenes que contienen incendios forestales e imágenes que no presentan incendios forestales. Donde las imágenes que presentan incendios, incluyen bosques y montañas con diferentes ángulos que incluyen flamas de fuego y/o humo. Las imágenes que no presentan incendios, incluyen bosques y montañas con diferentes ángulos, sin fuego o sin humo. La Figura 2 ilustra ejemplos representativos de imágenes de las 2 clases.

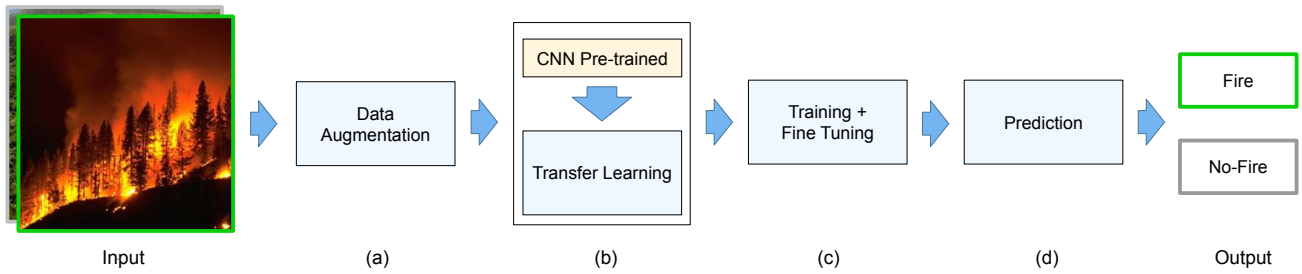


Figura 1. Método propuesto para la clasificación de incendios forestales. (a) *data augmentation*, (b) adaptación de modelos CNNs por *transfer learning*, (c) Entrenamiento de los modelos más *fine tuning*, (d) Evaluación del aprendizaje del modelo por la predicción de nuevas imágenes.




Figura 2. Ejemplos de conjunto de imágenes. Primera fila, 3 imágenes de incendios forestales. Segunda fila, 3 imágenes que no presentan incendios.

De forma similar como fue realizado con FFireNet [9], el conjunto de imágenes fue dividido en *Train*, *Test* y *Validation*. Donde, para el subconjunto *Test* fue considerado 20% del total, del restante de imágenes, el 80% fue atribuido para subconjunto *Train* y 20% fue atribuido para subconjunto *Validation*. La Tabla I muestra la distribución de la división de los subconjuntos.

Tabla I
DIVISIÓN DEL CONJUNTO DE DATOS DS1.

Clase	Train	Validation	Test	Total
Fire	608	152	190	950
No-Fire	608	152	190	950
Total	1216	304	380	1900

Adicionalmente, para la validación de los experimentos, también fue utilizado el conjunto de imágenes de dominio público DS2 [10], que es frecuentemente usado en competencias en el sitio kaggle.com. Una breve descripción de este conjunto es presentada en la Tabla II.

III-B. Aumento de datos

Con el propósito de incrementar la eficiencia de clasificación, 2 técnicas de procesamiento de imágenes son ejecutadas para generar nuevas versiones de las imágenes del subconjunto *train*. La primera técnica es conocida como *Horizontal Flip*,

Tabla II
DIVISIÓN DEL CONJUNTO DE DATOS DS2.

Clase	Train	Test	Total
Fire	2500	25	2525
No-Fire	2500	25	2525
Total	5000	50	5050

que trata de invertir los píxeles de la imagen en forma horizontal. La segunda técnica es denominada *Brightness Variations*, que incluye variaciones aleatorias de brillo sobre las imágenes utilizando el rango de valores desde 0,5 hasta 0,7, donde valores cercanos a 1,0 indican máximos valores de brillo para aumentar la iluminación en la imagen. Por otra parte, valores cercanos a cero predisponen un mayor grado de oscurecimiento en la imagen.

III-C. Transferencia de aprendizaje

Sobre la base de los pesos de CNNs preentrenadas con el conjunto ImageNet, en esta etapa las CNNs son adaptados eliminando la última capa de clasificación. Luego es agregada una última capa para brindar información de los resultados de clasificación. Esta nueva capa consta de 2 neuronas: la primera neurona tiene como objetivo obtener resultados para clasificar imágenes con incendios y la otra neurona brinda información para clasificar imágenes que no presentan incendios. Indicamos que no fueron agregadas capas densas adicionales, como sí fue realizado en caso del modelo FFireNet [6].

III-D. Entrenamiento

Con el objetivo de generar modelos más especializados en la clasificación de incendios, fue incluida la técnica de *fine tuning*. Donde el 10% del las últimas capas fueron configuradas para ser reentrenadas con las características del conjunto específico de imágenes de incendios forestales. El resto de capas no fueron reentrenadas, es decir, los pesos de las capas restantes son mantenidos, conservando de esta forma el aprendizaje obtenido con el conjunto ImageNet, esto también podría significar mayor rapidez en el proceso de reentrenamiento de las redes.

III-E. Predicción

En esta etapa, el aprendizaje de los modelos entrenados es evaluado utilizando las métricas: error, *precision*, *recall* y

accuracy. Es necesario resaltar que las imágenes utilizadas en esta etapa no forman parte del conjunto de imágenes utilizada en la etapa de entrenamiento.

III-F. Recursos de computación

Los experimentos fueron ejecutados en un computador de escritorio con las siguiente configuración: CPU Intel(R) con 16 CPU con 2.30 GHz, 16 GB RAM, GPU NVIDIA Tesla P100 de 16 GB de RAM. Empleamos Python 3.10.12 con Tensorflow/Keras 2.12.0 en Linux/Ubuntu 22.04 OS.

IV. RESULTADOS Y DISCUSIONES

En la ejecución de los experimentos fue utilizado el conjunto de imágenes descrito en la sección anterior. Para aminorar el tiempo de procesamiento, todas las imágenes fueron redimensionadas para 150×150 píxeles. Específicamente, el subconjunto de *train* fue utilizado en la etapa de *data augmentation*. Después, los subconjuntos *train* y *validation* fueron utilizados para generar aprendizaje de los modelos en etapa de entrenamiento. Por otra parte, el subconjunto de *test* fue empleado para evaluar el aprendizaje de los modelos en la etapa de predicción.

Cinco modelos de CNNs preentrenadas que son muy utilizadas para tareas de clasificación (Xception [11], MobileNet-v2, ResNet-50 [12], Inception-v3 [13] y DenseNet-201 [14]) fueron incluidos en la ejecución de la metodología propuesta. En los experimentos, específicamente en la etapa de entrenamiento, todos los modelos siguieron la configuración estática de los parámetros definidos en la Tabla III.

Tabla III
CONFIGURACIÓN DE LOS HIPER-PARÁMETROS.

Parámetros	Valor
Max epochs	20
Patience	7
Dropout	0.5
Loss function	Binary cross entropy
Optimizer	Adam
lear rate	0.0001
activation	softmax

Resultados cuantitativos son presentados en la Tabla IV. Los mejores resultados obtenidos con el modelo MobileNet, son presentados en las Figuras 3 y 4, estos representan resultados de *accuracy* en la etapa de entrenamiento y resultados de la matriz de confusión en la etapa de predicción, respectivamente. Adicionalmente, para tener una mejor visualización de las imágenes creadas por las técnicas propuestas por *data augmentation*, la Figura 5 ilustra ejemplos de imágenes generadas.

Comparando los resultados con el modelo de mayor precisión de la literatura, FFireNet (ver Tabla IV), se puede verificar la superioridad de la mayoría de los modelos generados con el método propuesto E-FFireNet, con excepción de modelo *Inception*. En términos de la métrica *accuracy*, el aumento en la precisión de los resultados de clasificación pueden tener influencia por la agregación de las técnicas de *fine tuning* y *data augmentation*. Es necesario indicar, que las técnicas

de *data augmentation* (horizontal flip y variación de brillo) utilizadas podrían destacar las características sobre las nuevas versiones de las imágenes, lo cual influenciaría para que los modelos puedan tener un mejor aprendizaje sobre imágenes de incendios forestales.

Tabla IV
RESULTADOS DE CLASIFICACIÓN PARA EL CONJUNTO DS1

Model	Error	Precision	Recall	Accuracy
E-FFireNet	0,263	99,476	100,000	99,737
Xception	0,789	98,953	99,474	99,211
DenseNet121	0,789	98,953	99,474	99,211
ResNet	1,842	98,413	97,895	98,158
FFireNet [6]	1,580	97,420	99,470	98,470
InceptionV3	1,579	98,421	98,421	98,421




Figura 3. Resultados del entrenamiento del modelo E-FFireNet (MobileNet).




Figura 4. Resultados de la predicción con modelo E-FFireNet (MobileNet).




Figura 5. Ejemplos de conjunto de imágenes con datos aumentados. Primera columna, imágenes originales, Segunda y tercera columna, imágenes aumentadas.

De forma complementaria, para la validación del aprendizaje de los cinco modelos entrenados, fueron seleccionados aleatoriamente 500 imágenes de cada clase (Fire, No-Fire) desde el subconjunto Train del conjunto de datos DS2. Luego las etiquetas para estas imágenes fueron calculadas por predicción utilizando los pesos de las redes ya entrenadas. Los resultados de este experimento son presentados en la Tabla V. Los resultados obtenidos se muestran consistentes con relación a los resultados obtenidos con el conjunto DS1 (ver Tabla IV). No obstante, para este conjunto de imágenes se aprecia mejores resultados con el modelo DenseNet121, donde los resultados de predicción son visualizados con una matriz de confusión en la Figura 6.

Concluyendo, los modelos MobileNet y DenseNet121 adaptados y reentrenados con el método E-FFireNet se muestran superiores sobre dos conjuntos de imágenes de clasificación de incendios forestales.

Tabla V
RESULTADOS DE CLASIFICACIÓN PARA EL CONJUNTO DS2.

Model	Error	Precision	Recall	Accuracy
E-FFireNet	5,700	92,843	96,000	94,300
Xception	5,100	93,762	96,200	94,900
DenseNet121	4,300	95,069	96,400	95,700
ResNet	4,800	95,935	94,400	95,200
InceptionV3	6,700	92,534	94,200	93,300

V. CONCLUSIONES

En este trabajo fue presentado E-FFireNet, un método para generar modelos de CNNs preentrenadas con aplicación específica en la clasificación de incendios forestales. E-FFireNet está centrada en la adaptación de redes CNNs preentrenadas empleando técnicas simples pero eficientes de *data augmentation*, *transfer learning*, *fine tuning*. Además, E-FFireNet no incluye la agregación de nuevas capas densas en los modelos, esto beneficia en aminorar el tiempo de entrenamiento manteniendo mejores resultados. Los resultados

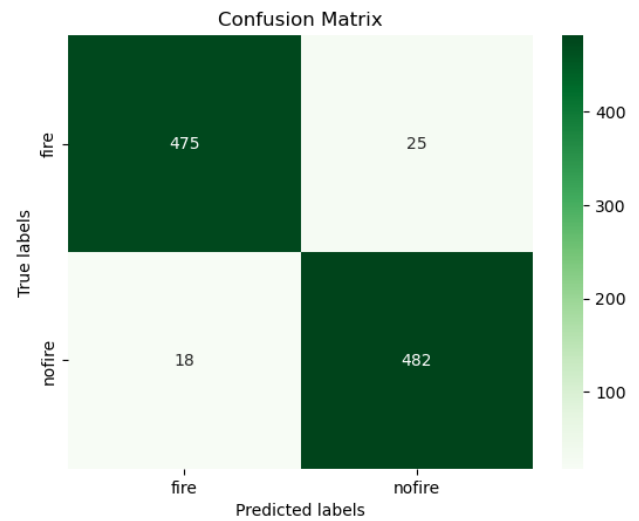


Figura 6. Resultados de la predicción con modelo E-FFireNet (DenseNet121).

obtenidos comparados con el modelo de referencia de la literatura, FFireNet, se muestran superiores considerando cuatro métricas de evaluación. La superioridad de los resultados junto a la simplicidad de las técnicas de *data augmentation* podrían ser factores determinantes para incluir E-FFireNet en futuras investigaciones donde se traten escenarios reales para la detección de incendios forestales.

REFERENCIAS

- [1] A. Khan, B. Hassan, S. Khan, R. Ahmed, A. Abuassba, and H.-j. Kim, "Deepfire: A novel dataset and deep transfer learning benchmark for forest fire detection," *Mob. Inf. Syst.*, vol. 2022, jan 2022. [Online]. Available: <https://doi.org/10.1155/2022/5358359>
- [2] J. Roces-Díaz, C. Santín, J. Martínez-Vilalta, and S. Doerr, "A global synthesis of fire effects on ecosystem services of forests and woodlands," *Frontiers in Ecology and the Environment*, 2021.
- [3] S. M. Juárez-Orozco, C. Siebe, and D. F. y Fernández, "Causes and effects of forest fires in tropical rainforests: A bibliometric approach," *Tropical Conservation Science*, vol. 10, p. 1940082917737207, 2017. [Online]. Available: <https://doi.org/10.1177/1940082917737207>
- [4] B. D. Cowled, M. Bannister-Tyrrell, M. Doyle, H. Clutterbuck, J. Cave, A. Hillman, K. Plain, C. Pfeiffer, M. Laurence, and M. P. Ward, "The australian 2019/2020 black summer bushfires: Analysis of the pathology, treatment strategies and decision making about burnt livestock," *Frontiers in Veterinary Science*, vol. 9, 2022. [Online]. Available: <https://www.frontiersin.org/articles/10.3389/fvets.2022.790556>
- [5] C. Li, Q. Liu, B. Li, and L. Liu, "Investigation of recognition and classification of forest fires based on fusion color and textural features of images," *Forests*, vol. 13, no. 10, 2022. [Online]. Available: <https://www.mdpi.com/1999-4907/13/10/1719>
- [6] S. Khan and A. Khan, "Ffirenet: Deep learning based forest fire classification and detection in smart cities," *Symmetry*, vol. 14, no. 10, 2022. [Online]. Available: <https://www.mdpi.com/2073-8994/14/10/2155>
- [7] H. Jabnoui, I. Arfaoui, M. A. Cherni, M. Bouchouicha, and M. Sayadi, "Machine learning based classification for fire and smoke images recognition," in *2022 8th International Conference on Control, Decision and Information Technologies (CoDIT)*, vol. 1, 2022, pp. 425–430.
- [8] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L.-C. Chen, "Mobilenetv2: Inverted residuals and linear bottlenecks," in *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2018, pp. 4510–4520.

- [9] A. Akagic and E. Buza, "Lw-fire: A lightweight wildfire image classification with a deep convolutional neural network," *Applied Sciences*, vol. 12, no. 5, 2022. [Online]. Available: <https://www.mdpi.com/2076-3417/12/5/2646>
- [10] A. SAIED. (2019) Fire dataset. [Online]. Available: <https://www.kaggle.com/datasets/phyllake1337/fire-dataset>
- [11] F. Chollet, "Xception: Deep learning with depthwise separable convolutions," in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 1800–1807.
- [12] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, pp. 770–778.
- [13] X. Xia, C. Xu, and B. Nan, "Inception-v3 for flower classification," in *2017 2nd International Conference on Image, Vision and Computing (ICIVC)*, 2017, pp. 783–787.
- [14] G. Huang, Z. Liu, L. Van Der Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," in *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017, pp. 2261–2269.