

Detecting A Medical Mask During The COVID-19 Pandemic Using Machine Learning: A Review Study

Mohammed A. AbdulGhani^{1*}, Laheeb M. Ibrahim²

^{1,2}Department of Software Engineering, College of Computer Sciences & Mathematics, University of Mosul, Mosul, Iraq

E-mail: [1*^{*}mohammedse44@gmail.com](mailto:mohammedse44@gmail.com), [2^{*}laheeb_alzubaidy321966@uomosul.edu.iq](mailto:laheeb_alzubaidy321966@uomosul.edu.iq)

(Received March 03, 2022; Accepted April 05, 2021; Available online June 01, 2022)

DOI: [10.33899/edusj.2022.133181.1221](https://doi.org/10.33899/edusj.2022.133181.1221), © 2022, College of Education for Pure Science, University of Mosul.

This is an open access article under the CC BY 4.0 license (<http://creativecommons.org/licenses/by/4.0/>)

Abstract:

Since the emergence of the COVID-19 pandemic, there have been government instructions to citizens to wear a medical mask in crowded places and institutions to prevent or reduce the spread of the pandemic, as the most common method of transmission of COVID-19 is (coughing or sneezing), the spread of infection of this disease can be reduced by wearing a mask Medical, and to ensure that everyone wears a mask is not easy.

In this paper, we try to study research in the field of identifying the medical mask and the machine learning algorithms used to build a system capable of detecting the medical mask in faces through images and video in real time. We also explain in this research an overview of the importance of machine learning and deep learning methods, especially Convolutional Neural Network (CNN) and the basic steps for creating the system We reveal the medical mask, and we highlight the methods and stages of building the model with its accuracy and get acquainted with the datasets used in building the model and the size of the data set (number of images) used in the training and testing phase of the model and the mechanism by which The researcher worked out to build his own system.

Keywords: Detection of medical mask, a convolutional neural network, machine learning, deep learning, prevention from the COVID-19.

الكشف عن الماسك الطبي أثناء جائحة كوفيد-19 (COVID-19) باستخدام تعلم الآلة: دراسة مراجعة

محمد عبدالستار عبدالغني^{1*} ، لهيب محمد إبراهيم²

^{2,1*} قسم البرمجيات، كلية علوم الحاسوب والرياضيات، جامعة الموصل، الموصل، العراق

الخلاصة:

منذ ظهور جائحة COVID-19 كانت هناك تعليمات حكومية للمواطنين بارتداء الماسك الطبي في الأماكن المزدحمة والمؤسسات لمنع او تقليل انتشار الجائحة، إذ ان أكثر طرق انتقال COVID-19 شيوعاً هو (السعال أو العطس)، يمكن تقليل انتشار عدوى هذا المرض من خلال ارتداء الماسك الطبي، ولضمان ارتداء جميع الأشخاص للماسك الطبي ليس بالأمر السهل.

نحاول في هذا البحث دراسة البحوث للتعرف على الماسك الطبي و خوارزميات تعلم الآلة المستخدمة لبناء نظام قادر على الكشف الماسك الطبي في الوجوه من خلال الصور والفيديو في الوقت الحقيقي ، نوضح في هذا البحث ايضا نبذة عن اهمية تعلم الآلة وطرق التعلم العميق، لاسيما الشبكة العصبية التلافيفية (CNN) والخطوات الاساسية لإنشاء النظام الكشف عن الماسك الطبي ، ونسلط الضوء على طرق ومراحل بناء النموذج مع دقته ونتعرف على مجموعة البيانات (Datasets) المستخدمة في بناء النموذج وحجم مجموعة البيانات(عدد الصور) المستخدمة في مرحلة التدريب والاختبار النموذج وآلية التي عمل بها الباحث لبناء النظام الخاص به.

الكلمات المفتاحية: الكشف عن الماسك الطبي، الشبكة العصبية التلافيفية، تعلم الآلة، التعلم العميق، وقاية من فايروس كورونا.

1. المقدمة

أعلنت منظمة الصحة العالمية في آذار سنة 2020 ان فيروس كورونا المستجد المسبب لمرض "كوفيد-19" والذي يتفشى في مختلف أرجاء العالم "وباءً عالمياً" [1]. منذ ذلك الحين أصدرت المنظمة مجموعة من الارشادات من اهمها ارتداء الماسك الطبي، تتضمن الارشادات ونصائح لصناع القرار في الدول والمجتمعات بشأن استخدام الأشخاص المصابين والأصحاء الماسك الطبي. ينتشر مرض COVID-19 بشكل رئيسي من شخص الى اخر عن طريق الرذاذ التنفسي. حيث تنتقل قطرات الجهاز التنفسي إلى الهواء عندما يسعل الشخص أو يعطس أو يتحدث أو يصرخ. ولهذا يعتبر الماسك الطبي عائقاً بسيطاً للمساعدة في منع وصول قطرات الجهاز التنفسي إلى الآخرين. تشير الدراسات إلى أن الماسك الطبي يقلل وصول رذاذ القطرات من شخص الي اخر [2]. ان الاماكن التي يتوجب ارتداء الماسك الطبي والتي يتم فرضها وهي مثلا الحرم الجامعي، والمتاجر، والمستشفيات، المطارات، البنوك، المصانع والمحطات، وما إلى ذلك حيث يتم تخصيص اشخاص لفحص ارتداء الماسك الطبي ويتم ذلك يدويا وهذه الطريقة تسبب اهدار للوقت والموارد البشرية وهناك احتمال كبير في فقد الكشف او الانتغال اثناء الفحص. في الآونة الاخيرة أدخلت التطورات الحديثة في مجال الرؤية الحاسوبية وتعلم الآلة (Machine Learning) والتعلم العميق (Deep learning) سهولة تصميم نماذج للكشف والتمييز في مجالات متعددة حيث يقدم التعلم العميق الذي هو جزء من تعلم الآلة خطوات كبيرة في مجموعة متنوعة من مشاكل الرؤية الحاسوبية، مثل التعرف على الاشياء وتتبع الحركة، التعرف على الإجراءات، وتقدير الوضع البشري وتصنيف الاشياء وما الى ذلك. تناولت الدراسة استعراض البحوث والدراسات التي تمت في مجال تمييز الماسك الطبي الموضوع على الأنف والفم، وبيان مدى فعالية (أو كفاءة) خوارزميات تعلم الآلة المستخدمة على مجموعة من صور الأشخاص مرتدي الماسك الطبي وغير مرتدي الماسك الطبي.

يتضمن البحث: الفقرة الثانية التي تتناول تعلم الآلة والتعلم العميق، الفقرة الثالثة وتتناول خوارزميات التعلم العميق، الفقرة الرابعة تلخص الخطوات اساسية في تصميم نظام الكشف عن الماسك الطبي باستخدام خوارزميات التعلم العميق (نموذج MobilNetV2) ، الفقرة الخامسة تتناول الدراسات السابقة، واخيرا الفقرة السادسة تتناول الاستنتاجات.

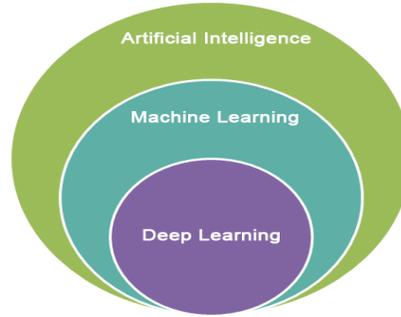
2. تعلم الآلة والتعلم العميق

تعلم الآلة (Machine Learning)، هو أحد الفروع المنبثقة عن علم الذكاء الاصطناعي القائمة على برمجة الحواسيب بمختلف أشكالها لتصبح قادرةً على أداء المهام وتنفيذ الأوامر الموكلة إليها بالاعتماد على البيانات المتوفرة لديها وتحليلها مع تقييد التدخل البشري في توجيهها أو تغييره تماماً. ويشار إلى أن مصطلح تعلم الآلة قد ظهر بإيعازٍ من رائد الذكاء الاصطناعي آرثر سامويل في سنة

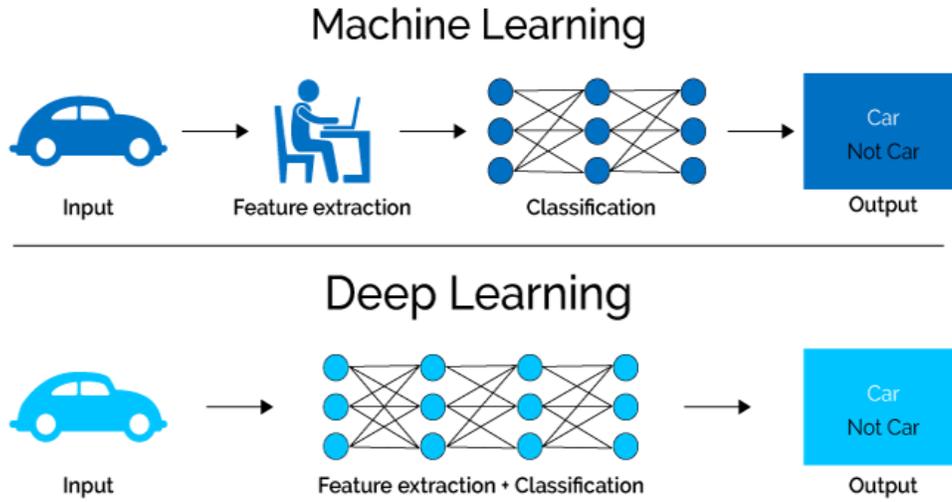
1959 ضمن نطاق عمل مختبرات IBM ، ومن الجدير بالذكر فإن الآلة في هذه الحالة يجب أن تعتمد على تحليل البيانات المدخلة إليها مسبقاً لمواجهة الأوامر والمهام المطلوبة منها، فيكون دور العنصر البشري ضئيلاً جداً في نهاية المطاف [3]. ويقع على عاتق الآلة مسؤولية اتخاذ القرار عند الحاجة لذلك، وتحديد ما يجب تنفيذه من مهام ومتى وكيف ولماذا دون أي مساعدة بشرية إطلاقاً، إذ سيسهم ذلك حتماً في إنجاز المهام بأسرع وقتٍ ممكن مقارنةً مع الوقت الذي يستهلكه البشر لإنجاز المهام. يتضمن تعلم الآلة عدداً كبيراً من حقول التطبيقات: معالجة اللغات الطبيعية ، تمييز الأنماط ، المعلوماتية الحيوية ، المعلوماتية الكيميائية و تمييز الكلام ... الخ [4] [5].

تعتمد الخوارزميات المستخدمة في تعلم الآلة على مجموعةٍ من النماذج الرسومية وأدوات القرار كشجرة القرار ومعالجة اللغات الطبيعية والشبكات العصبية الاصطناعية للقيام بمهمة أتمتة البيانات المُحللة والمعالجة؛ وبالتالي تحفيز الآلة على اتخاذ القرار والقيام بالمهام الموكلة لها بكل سهولة [6]. وهناك طرق تقليدية في تعلم الآلة وهي شجرة القرار، والغابة العشوائية، وتعزيز التدرج الأقصى، والانحدار اللوجستي. ولا بد من الإشارة إلى أن الشبكات العصبية الاصطناعية المستخدمة في تعلم الآلة تؤدي دوراً في غاية الأهمية يضاهاي دور الأعصاب وشبكاتهما في جسم الإنسان البشري ودماعه، وانطلاقاً من الدور المعقد الذي تقوم به الخوارزميات وأدواتها فقد ظهرت الحاجة الملحة بما يُعرف بالتعلم العميق (Deep Learning) [7].

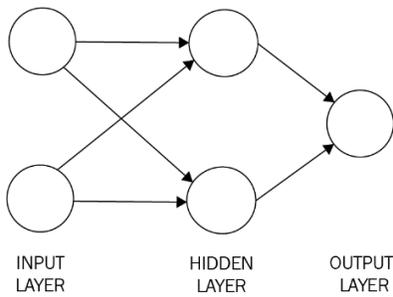
التعلم العميق (Deep Learning) هو مجال بحث جديد يتناول إيجاد نظريات وخوارزميات تتيح للآلة أن تتعلم بنفسها عن طريق محاكاة الخلايا العصبية في جسم الإنسان، وأحد فروع العلوم التي تتناول علوم الذكاء الاصطناعي. يعد فرع من فروع علوم التعلم الآلي، لاحظ الشكل (1)، تركز معظم أبحاث التعلم المتعمق على إيجاد أساليب استنباط درجة عالية من المتجرّدات بتحليل مجموعة بيانات ضخمة باستخدام متحولات خطية وغير خطية [8][9][10]. لاحظ الأشكال (2, 3, 4)



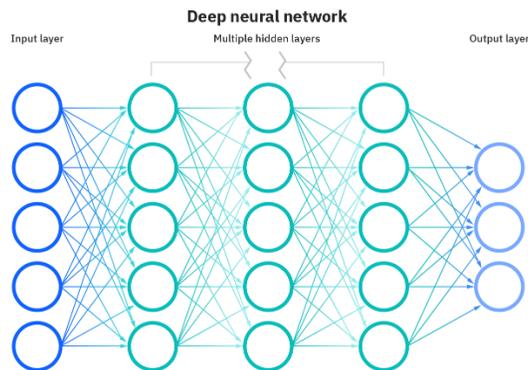
الشكل 1: العلاقة بين الذكاء الاصطناعي والتعلم الآلي والتعلم العميق [11].



شكل 2: عملية استخراج الميزات لخوارزميات التعلم الآلي [12].



الشكل 3: الشبكة العصبية البسيطة [13].



الشكل 4: الشبكة العصبية العميقة [14].

3-أنواع شبكات التعلم العميق

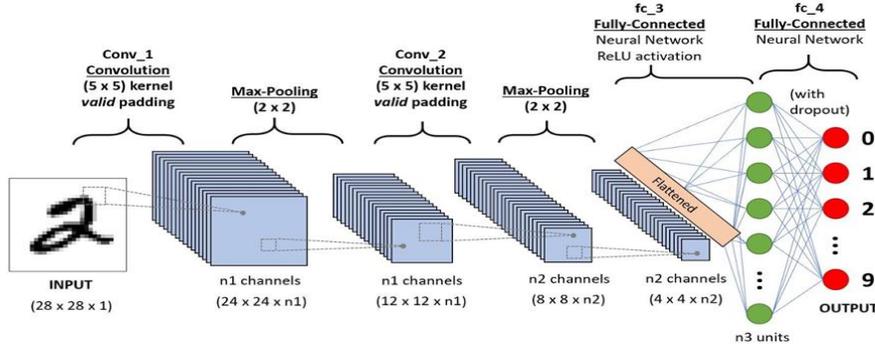
يوجد ثلاث أنواع من شبكات التعلم العميق وهي:

- ❖ **الشبكة العصبية الأمامية التغذية (Feed-Forward Neural Network):** وهي من الشبكات العصبية البسيطة والاساسية للغاية، حيث تنتقل البيانات أو المدخلات (input layer) في اتجاه واحد. تمر البيانات عبر عقد الإدخال وتخرج من عقد الإخراج (output layer). قد تحتوي هذه الشبكة العصبية على طبقات مخفية، فلا توجد تقنية الاسترجاع العكسي (BackPropagation) في هذا النوع من الشبكة [15][16].
- ❖ **الشبكة العصبية المتكررة (Recurrent Neural Network):** الشبكة العصبية المتكررة (RNN) هي فئة أخرى من الشبكات العصبية الاصطناعية إذ يتم تغذية مخرجات خلية عصبية معينة مرة أخرى كمدخل إلى نفس الخلية، تساعد هذه الطريقة الشبكة العصبية على التنبؤ بالمخرجات [17][18].
- ❖ **الشبكة العصبية التلافيفية (Convolutional Neural Network):** تسمى ايضا ConvNets، تحتوي هذه الشبكة على طبقات متعددة كما أظهرت ConvNets أداءً ممتازاً في العديد من التطبيقات مثل تصنيف الصور واكتشاف الأشياء والتعرف على الكلام ومعالجة اللغات الطبيعية وتحليل الصور الطبية [19] [20]. يوجد عدة معماريات جاهزة لـ CNN مصنفة حسب تاريخ انشائها مثل (LeNet-5, AlexNet, VGG-16, Inception-v1, Inception-v3, ResNet-50, Xception,) لدى CNN ثلاثة أنواع رئيسية من الطبقات، وهي:

1- **طبقة الالتفاف (Convolution Layer):** هذه الطبقة هي الطبقة الأولى التي يتم عن طريقها استخراج الميزات المتنوعة من الصور المدخلة (input). في هذه الطبقة، تنفذ العملية الرياضية للالتفاف بين الصورة المدخلة ومرشح بحجم معين مثلا الصورة المدخلة بحجم 224x224 والمرشح بحجم 7x7 فمن خلال تحريك المرشح فوق صورة الإدخال(التفاف)، يتم أخذ حاصل الضرب النقطي (Dot product) بين المرشح وأجزاء صورة الإدخال وحسب حجم المرشح في تلك الموقع. يُطلق على الإخراج اسم خريطة الميزات (Feature map) التي تعطينا معلومات حول الصورة مثل الزوايا والحواف. لاحقاً، تغذى خريطة الميزات (Feature map) هذه إلى طبقات أخرى للتعرف على العديد من الميزات الأخرى للصورة المدخلة [22].

2- **طبقة التجميع (Pooling Layer):** الهدف الأساسي من هذه الطبقة هو تقليل حجم خريطة الميزات (Feature map) الذي تم استخراجه من طبقة السابقة لتقليل العمليات الحسابية. عادة ما تعمل طبقة التجميع كجسر بين الطبقة الالتفاف وطبقة الاتصال الكامل ((Fully connected (FC) [23].

3- **طبقة الاتصال الكامل (Fully Connected Layer):** تعتبر FC من طبقات الاخيرة في المعمارية، تتكون من الأوزان جنباً إلى جنب مع الخلايا العصبية وتستخدم لربط الخلايا العصبية بين طبقتين مختلفتين. المدخلات لهذه الطبقة هو عملية بسط (Flattening) للطبقات السابقة القادمة اليه اي تحويل ذات المصفوفات الثنائية الى مصفوفة واحدة احادية إذ تتم عادةً عمليات الرياضيات كما يتم في شبكة العصبية الأمامية التغذية (FNN). في هذه المرحلة، تبدأ عملية التصنيف [24]، الشكل 5 يوضح طبقات الشبكة العصبية التلافيفية.



الشكل 5: معمارية الشبكة العصبية التلافيفية لتصنيف الأرقام المكتوبة بخط اليد [25].

الشكل (5) يوضح معمارية الشبكة العصبية التلافيفية لتصنيف الأرقام المكتوبة بخط اليد، إذ يتم ادخال صورة بحجم 24×24 ذات طبقة واحدة ويتم التقافه بمرشح (Filter) بحجم 5×5 ويتم تمريرها الى طبقة التالية MaxPooling ومن ثم عمل Flatten والى عملية FC مع طبقة الاخراج (Output layer) وتتم عملية التصنيف ليتنبأ بالرقم 2.

4-خطوات اساسية لإنشاء نظام الكشف عن الماسك الطبي باستخدام خوارزميات التعلم العميق (نموذج MobilNetV2)

نوضح في هذه الفقرة الخطوات الأساسية في تصميم نظام الكشف عن الماسك الطبي باستخدام خوارزميات التعلم العميق (نموذج

MobilNetV2) وكما يلي:

1. جمع وتجهيز قاعدة البيانات الخاصة بتصنيف الماسك الطبي (صور وجوه بماسك طبي / بدون ماسك طبي): يمكن تنزيلها من موقع Kaggle ، لنفترض 1200 صورة (600 صورة صور وجوه بماسك طبي 600 صورة لوجوه بدون ماسك طبي) ، لاحظ شكل (6).



شكل 6: قاعدة بيانات تحتوي على (صور وجوه بماسك طبي / بدون ماسك طبي) [26].

هدفنا من قاعدة البيانات هو تدريب نموذج التعلم العميق المخصص للكشف عن الماسك الطبي.

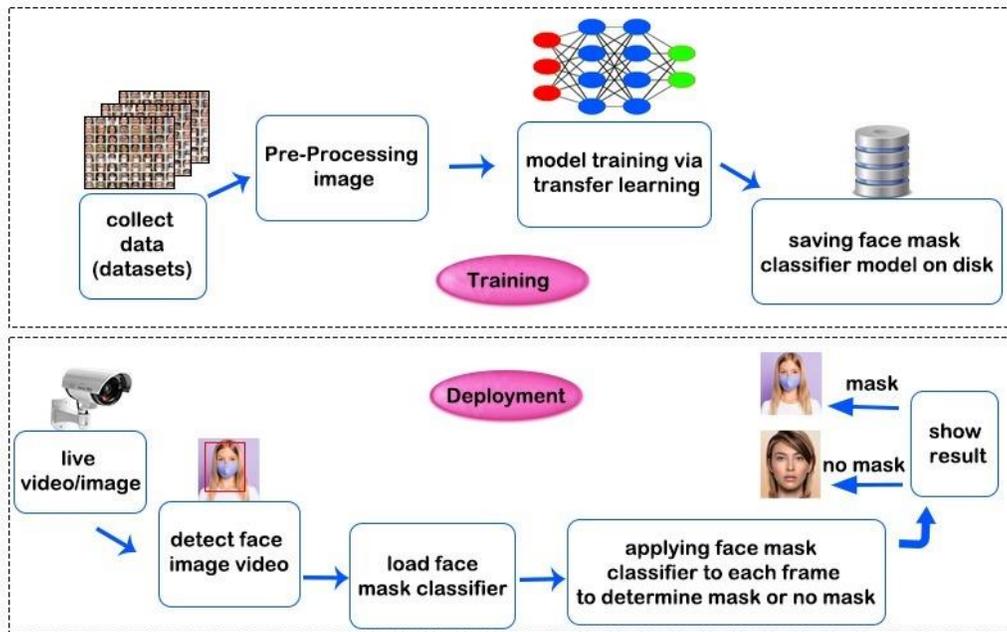
2. استخدام مكتبة خاصة بالتعلم العميق ورؤية الكمبيوتر: مثل Tensorflow ، Scikit-learn ، Keras ، OpenCV المتوفرة بلغة بايثون [9].

3. المعالجة المسبقة للبيانات (Pre-Processing): وتتضمن التسمية (Labeling) الصور وهما with_mask و without_mask ، تحويل ابعاد الصور الى 224×224 باستخدام مكتبة Keras (ذلك لأن النموذج الذي نستخدمه يتعامل

مع صور ملونة بأبعاد 224×224 بيكسل) ، تحويل مجال قيم بكسلات صورة من 0-255 إلى 0-1 وهذا يفيد في تسريع عملية التدريب ، تقسم البيانات الى 70% كبيانات تدريب و30% كبيانات اختبار باستخدام مكتبة Scikit-learn.

4. **عملية التدريب والاختبار:** تحميل النموذج MobileNet: نريد في هذا النموذج تصنيف الصورة المدخلة الى صنفين رئيسيين أما with_mask أو without_mask أي جعل طبقة الإخراج تحوي عصبونين (هذا ما يعرف "Transfer Learning" [19]) و تدريبها على البيانات التي تمت معالجتها مسبقا وهنا عملية التدريب فقط تتضمن تعديل أوزان طبقة الإخراج، بالنهاية نقوم برسم منحى التدريب ومنحنى الدقة ومن خلالهما يمكن معرفة حالة النموذج اذا كان يعاني من مشاكل معينة أم لا باستخدام مكتبة Matplotlib ، بعد ان انتهينا من عملية بناء النموذج نقوم بعملية التدريب لاختبار كفاءته ويحفظ النموذج.

5. **تنفيذ النموذج:** يستخدم أحد النماذج لتحديد الوجوه ومن ثم تمريرها الى النموذج للكشف عن ماسك الطبي وبهذا يبنى نموذج التصنيف لمعرفة إذا كان الوجه يرتدي الماسك الطبي أم لا. (لاحظ شكل (7))



شكل 7: لإنشاء نظام الكشف عن الماسك الطبي باستخدام خوارزميات التعلم العميق.

5-الدراسات السابقة

في هذه الفقرة نتناول الدراسات التي بحثت في مجال تمييز الماسك الطبي باستخدام خوارزميات التعلم الآلي والتعلم العميق وكما يلي:

يلي:

قام Sanjaya, S.A وآخرون في عام 2020 في دراستهم بتطوير نظام تعرف على الوجه من خلال تدفق الفيديو باستخدام تعلم الآلة، حيث تم بناء النموذج الخاص بهم باستخدام MobileNetV2 وهي بنية الشبكة العصبية التلافيفية تسعى إلى الأداء الجيد على الأجهزة المحمولة، بني النموذج باتباع خطوات التالية: جمع البيانات والمعالجة المسبقة وتقسيم البيانات واختبار النموذج وتنفيذ النموذج، أجريت هذه الدراسة تجاربها على مجموعتي بيانات أصليتين. أخذت مجموعة البيانات الأولى من مجموعة

بيانات Kaggle ومجموعة بيانات (Real-World Masked Face) RMFD ، تستخدم هذه الدراسة 1916 صورة مع ماسك الطبي و1930 صورة بدون ماسك الطبي، حقق النموذج الدقة 96.85% بالمائة [27].

اقترح Das, A. وآخرون في سنة 2020 في بحثهم نظام اكتشاف الوجوه المقنعة من الغير المقنعة في الصور، ذكر الباحث انه أنشئ النظام مع حزم تعليم الآلي مثل TensorFlow و Keras و OpenCV و Scikit-Learn. تم استخدام نموذج المدرب مسبقا Cascade Classifier لكشف الوجه، ومن ثم بناء النموذج باستخدام بنية CNN. أجري التدريب لنموذجهم المقترح على مجموعتين من البيانات (Datasets)، تتكون مجموعة البيانات الأولى من 1376 صورة فيها 690 صورة لأشخاص يرتدون الماسك والباقي 686 صورة لأشخاص لا يرتدون الماسك الوجه، تتكون مجموعة البيانات الثانية المأخوذة من Kaggle من 853 صورة إما بماسك الطبي أو بدون ماسك الطبي. مع مجموعة بيانات الأولى ذكر الباحث انه حصل على دقة تصل إلى 95.77%. اما المجموعة الثانية فكانت الدقة 94.58%. وذكر الباحث انه يمكن تحسين اداء النموذج من خلال تحسين طبقة MaxPooling، حيث ان هذه الطبقة يقوم بتقليل عدد الخلايا العصبية. يمكن أن يؤدي وجود عدد أكبر من الخلايا العصبية إلى أداء أسوأ [32].

سنة 2020 اجريت دراسة بعنوان "Face Mask Detection using YOLOv5 for COVID-19" بواسطة Sharma, V. حيث تم تصميم نظام لكشف الماسك الطبي في وقت الحقيقي، قسم الباحث المشروع الى اربع مراحل : الأولى هي جمع البيانات ، والمرحلة الثانية هي تطوير النموذج ، والمرحلة الثالثة هي تدريب النموذج ، والمرحلة الأخيرة هي اختبار النموذج المطور. من بين الأدوات والتقنيات المستخدمة هم NumPy و TensorFlow و OpenCV يتم استخدامها بلغة Python. استخدم الباحث خوارزمية YOLOv5، هذه خوارزمية أساسية للتعلم الآلي لاكتشاف الأشياء. الغرض منه هو تمييز الأشياء من الفيديو أو الصورة، واستخدم هذا النموذج لتحديد ماسك الطبي من الفيديو. تم اختبار النموذج باستخدام YOLOv5s وكذلك YOLOv5x اكتملت عملية التدريب من خلال تشغيلها في Google Collab (هو مشروع يتيح البرمجة لجميع الراغبين بالتعلم دون الحاجة الى كومبيوترات ذات مواصفات عالية حيث يتم استخدام الحواسيب السحابية) ذكر الباحث ان اداء النموذج YOLOv5s أفضل تماماً من YOLOv5x من حيث الأداء والسرعة [36].

وفي سنة 2020 اقترح Mehendale, N. وآخرون في بحثهم نظام الكشف عن الماسك الطبي في وقت الحقيقي باستخدام التعلم العميق تم تسمية نموذجهم بـ Facemasknet تقدم النموذج تصنيفاً من ثلاث فئات، أي أن الشخص يرتدي الماسك، أو يرتدي الماسك بشكل غير صحيح أو لم يتم اكتشاف الماسك في الوجه حسب ما تم ذكره، يصنف النموذج الحالات التي يتم فيها ارتداء الماسك بشكل غير صحيح هي عندما يتم تغطية الأنف والقم جزئياً. ذكر ان النموذج الخاص بهم حصل على دقة 98.6% [38].

وفي سنة 2020 قدم Qin, B. وآخرون في بحثهم طريقة لتعرف على الوجه في حالة ارتداء الماسك الطبي على الوجه. احتوت الخوارزمية المقترحة على أربع خطوات رئيسية: المعالجة المسبقة للصورة، واكتشاف الوجه والاقتصاص، والدقة الفائقة للصورة (Image Super-Resolution)، وتحديد ظروف ارتداء ماسك الطبي. تم تدريب الطريقة وتقييمها على مجموعة بيانات عامة من Medical Masks، تحتوي على 3835 صورة، وذكر الباحث ان الطريقة عمل نموذجهم حصل على دقة 98.70% [39].

في عام 2021 قدم Sethi, S. وآخرون في بحثهم إلى ابتكار تقنية في الوقت الحقيقي يمكنها الكشف عن الوجوه غير المقنعة في الأماكن العامة، تألف هيكل النموذج الخاص بهم تحت ثلاث مكونات رئيسية: العمود الفقري والرقبة والرأس (Backbone, Neck, Head) هنا إذ يتم في العمود الفقري مهام استخراج المعلومات من الصور وتحويلها إلى خريطة الميزات (Feature map) أي يتوافق مع شبكة عصبية تلافيفية (يتم تطبيق مفهوم نقل التعلم) ، تم تطبيق استراتيجيات على العمود الفقري مع ثلاثة نماذج مشهورة مدربة مسبقاً وهي ResNet50 و MobileNet و AlexNet. وجد ان ResNet50 ليكون الاختيار الأمثل لبناء العمود الفقري لنموذجهم المقترح. اما الرقبة يحتوي على كل مهام المعالجة المسبقة المطلوبة قبل التصنيف الفعلي للصور، المكون الأخير الرأس، يرمز إلى كاشف الهوية أو المتنبئ الذي يمكنه تحقيق هدفهم المنشود للشبكة العصبية للتعلم العميق. لوحظ أن التقنية المقترحة تحقق دقة 98.2% [28].

في عام 2021 يقترح Shah, R. وآخرون استخدام الشبكة العصبية التلافيفية CNN طريقة للكشف عن أقنعة الوجه التي يتم وضعها أو عدم وضعها على الوجوه من خلال تدفق الفيديو في وقت الحقيقي و يتم وضعها في المكاتب و الاماكن المشابه لها ،نموذج الشبكة العصبية التلافيفية المستخدمة في بحثهم هو بنية MobileNetV2 . تم تصميم النموذج المقترح هنا ونمذجته باستخدام مكتبات Python وهي TensorFlow و Keras و OpenCV، يتم استخدام البنية هذا باستخدام طريقة نقل التعلم Transfer Learning (يتم استخدام نقل التعلم وهي المعرفة المكتسبة أثناء حل مشكلة واحدة وتطبيقها على مشكلة مختلفة ولكنها ذات صلة. على سبيل المثال، يمكن تطبيق المعرفة المكتسبة أثناء تعلم التعرف على مجموعة مختلفة من الصورة عند محاولة التعرف على الماسك الطبي اي يتم اعادة استخدام نموذج مدرب مسبقا الى تدريبها مع بيانات جديدة) ذكر الباحث انه يمكن توصيل النظام بأي نظام مراقبة مثبت في مقر العمل وعلى السلطات أو المشرف وضع النظام بها والتحقق من الشخص من خلال النظام لتأكيد هويته، ويرسل النظام رسالة تنبيه إلى الشخص المخول إذا دخل شخص ما إلى المبنى بدون ماسك طبي. بعد تدريب نموذجهم على مجموعة البيانات ذكر ان معدل دقة الكشف عن شخص بالماسك في نموذجهم هو 95-97% [29].

في سنة 2021 Talahua, J.S. وآخرون قدموا في بحثهم نظاماً للتعرف على الأشخاص ، حتى عندما يستخدمون الماسك الطبي من الصور باستخدام تعليم الآلي، استخدموا قاعدتي البيانات: الأولى صور الأشخاص الذين يرتدون أقنعة الوجه وآخرين لا يرتدونها والثاني يستخدم لتدريب نظام التعرف على الوجه ، البنية المستخدمة هي MobileNet ، استُخدم قاعدة البيانات "Real-World-Masked-Face-Dataset" المتاحة على Git-Hub ، نكر الباحث ان بنية MobileNetV2 أسرع بنسبة 35% في اكتشاف الأشياء مقارنة بالإصدار الأول ، عند دمجهم مع Single Shot Detector Lite (مزيد من المعلومات حول SSD في [30])، يتم استخدام "نقل التعلم" في الطبقات الأخيرة لتطبيقها على الفكرة المقترحة ، اما بالنسبة لتعرف على الوجه فتم استخدام نموذج الكشف عن الوجه المستند إلى OpenCV Deep Learning وأجريت الخطوات التالية: (1) خلال أسبوع ، تم الحصول على مقاطع فيديو يومية لوجه كل فرد ، بهدف التقاط زوايا مختلفة وظروف بيئية مختلفة . (2) من مقاطع الفيديو التي تم الحصول عليها، تم التقاط الصور في لحظات مختلفة. في نهاية الاجراء يتم وضع الاسماء على الاشخاص على الصور الملتقطة ويتم عملية التدريب. ذكر الباحث ان تم الحصول على 99.65% في تحديد ما إذا كان الشخص يرتدي الماسك الطبي أم لا. و تم تحقيق دقة 99.52% في التعرف على الوجه لعشرة أشخاص بأقنعة، بينما تم الحصول على دقة 99.96% للتعرف على الوجه بدون ماسك طبي[31].

سنة 2021 اقترح Adusumalli, H. وآخرون في بحثهم نظام اكتشاف الماسك الطبي تحت عنوان " Face Mask Detection Using OpenCV" ذكر الباحث الغرض من استخدام هذا النظام وهو استخدامه في الأماكن العامة مثل محطات السكك الحديدية ومراكز التسوق كما انه سيكون عوناً كبيراً للشركات والمؤسسات الضخمة. استُخدمت في المشروع التعلم الآلي باستخدام TensorFlow و OpenCV. استخدم النموذج MobileNetV2 لتدريب على 3835 صورة، منها 1916 صورة بها أشخاص بأقنعة و 1919 شخصاً بدون أقنعة (يتم استخدام نقل التعلم في النماذج المدربة كما ذكرناها سابقاً). يتم انشاء نموذج اخر يتم تدريبه على وجوه البشر. يتم توفير الصور المستخدمة لتدريب النموذج مع الاسم وعنوان البريد الإلكتروني لهذا الشخص كتسميات (Labeling) لتلك الصور. يتم ذلك باستخدام OpenCV ، هنا يتم برز فكرة المشروع إذ يتم استخراج الوجه الغير مقنعة الى نموذج التعرف على الوجه فإنه يكتشف اسم الشخص الذي لا يرتدي ماسك طبي وسيتم إرسال بريد إلكتروني إلى هذا الشخص يحذره من أنه لا يرتدي الماسك حتى يتمكن من اتخاذ الاحتياطات [33].

سنة 2021 قدم Suresh, K. وآخرون اقترحوا في بحثهم نظاماً لكشف اقنعة الوجه من خلال تدفق الفيديو في وقت الحقيقي تحت عنوان "Face Mask Detection by using Optimistic Convolutional Neural Network" ، ذكر الباحث انه باستخدام حزم تعلم العميق TensorFlow و Keras تم تدريب مجموعة البيانات مأخوذة من موقع Kaggle تضم حوالي 3918 صورة لأشخاص بأقنعة وبدون أقنعة تضمنت العملية أيضاً استخدام النموذج MobileNet لإجراء عملية التدريب ، ذكر الباحث ان تم استخدام النموذج MobileNet بدلاً من نماذج اخرى مدربة مثل ResNet وذلك لأنه من الممكن ان يتم استخدام النظام على جهاز محمول أو أي جهاز مضمن ، حيث تكون مواصفات الحوسبة مقيدة للغاية ، فقد تم اقتراح MobileNet بحيث تكون النفقات الحسابية لشبكة هذه أقل بكثير مقارنة بالشبكات الاخرى حسب رأيه [34].

Sreevani, P. وآخرون في سنة 2021 اقترحوا في بحثهم نظاماً لتحديد ما إذا كان الشخص يرتدي الماسك الطبي أم لا، تكمن الفكرة وراء بحثهم هو استخدام ثلاث شبكات عصبية: الشبكة العصبية التلافيفية التي تتم مقارنتها بشبكة MobileNetV2 و Vgg16 والاعلان الافضل فيما بينهم، يتم استخدام مجموعة بيانات ماسك الطبي للوجه التي تحتوي على 5000 صورة لأشخاص يرتدون الماسك وآخرون وبدون الماسك. تم تنزيل مجموعة بيانات (Datasets) من موقع Kaggle. تم تقسيم مجموعة البيانات إلى مجموعتين، واحدة للتدريب والآخر للاختبار النظام. يتم إعطاء 80% للتدريب من الصور و 20% للاختبار. بعد المعالجة المسبقة لمجموعة البيانات تم ادخال البيانات الى النماذج. حصل Vgg16 على دقة 89% و MobileNetV2 حصل على دقة 94% بينما حصل الشبكة العصبية التلافيفية CNN العادية على 85%. بالمقارنة مع دقة النماذج فإن MobileNetV2 أفضل معدل من حيث الدقة وأكثر كفاءة من الناحية الحسابية كما يدعي الباحث [35].

سنة 2021 أجري Yu, J. وآخرون دراسة حول تعرف على الماسك الطبي بناءً على خوارزمية YOLO-v4 المحسن، تم استخدام خوارزمية CSPDarkNet53 المحسن لاستخراج الميزات، ذكر انه يقلل من تكلفة الحسابية للشبكة ويحسن القدرة التعليمية للنموذج مع خوارزميات اخرى لتحسين الدقة، تم استخدام مجموعة بيانات RMFD و MaskedFace-Net اي مجموع الصور 10855 منها 7826 صورة للتدريب و 868 صورة لقياس دقة (verification) و 2161 صورة للاختبار، وأشار ان نتائج الدقة النموذج وصل الى 98.3% حسب ما تم ذكره [37].

سنة 2021 قدم Mandal, B. وآخرون في بحثهم تطوير نموذج قائم على التعلم العميق قادر على تحديد الأشخاص الذين يستخدمون أقنعة الوجوه (الماسك)، حيث تم استخدام بنية ResNet-50 المدربة مسبقاً لمشروعهم من خلال نقل التعلم (Transfer Learning)، ذكر الباحث ان هذه البنية تتمتع بأداء أفضل في الوقت والذاكرة عند مقارنتها بـ VGGNet19 وDenseNet121، تم استخدام مجموعة بيانات (Real-world masked face recognition dataset) RMFRD، ذكر الباحث ان النموذج الخاص بهم حصل على نسبة دقة 89.7% [40].

سنة 2021 اجريت دراسة بواسطة Solin, L. وآخرون يوضح فيها تطوير نظاماً والتي يمكن أن تحدد ما إذا كان المشاة يرتدون أقنعة أم لا ، تم استخدام واجهة برمجة تطبيقات الكائنات TensorFlow (TensorFlow object detection API) لتدريب كاشف الكائنات على اكتشاف الوجوه غير المقنعة والمقنعة من الصور ، ذكر الباحث انه تم برمجة النظام بواسطة البرمجة النصية باستخدام Python تم تدريب النموذج على مجموعة بيانات FMLD والذي يحتوي على 41900 صورة ، ذكر الباحث انه تحصل على دقة 86.4% بعد محاولة الثانية لتحسين النموذج [41].

الجدول (1) يوضح ملخص البحوث والدراسات التي اجريت في مجال اكتشاف الماسك الطبي باستخدام طرق التعلم الآلي
جدول (1) ملخص البحوث والدراسات التي اجريت في مجال الكشف عن الماسك الطبي باستخدام طرق التعلم الآلي.

السنة	دقة النموذج	حجم البيانات (صورة)	مجموعة بيانات	الخوارزمية	رقم المرجع	ت
2020	96.85%	3846	RMFD	MobileNetV2	27	1
2020	95.77%	1376	From Kaggle Repository	Deep learning library	32	2
2020	98.6%	35	Created by user	(Deep learning) Facemasknet	38	3
2020	98.70%	3835	Medical Masks	Deep learning library	39	4
2021	99.96%	13359	RWMFD	MobileNet	31	5
2021	98.2%	5000		ResNet50, MobileNet, AlexNet	28	6
2021		3835	From Kaggle Repository	MobileNetV2	33	7
2021		3918	From Kaggle Repository	MobileNet	34	8
2021	94%	5000	From Kaggle Repository	MobileNetV2, Vgg16, custom CNN	35	9
2021	98.3%	10855	MaskedFace-Net, RMFD	YOLO-v4	37	10
2021	89.7%	95000	RMFRD	ResNet-50	40	11
2021	86.4%	41900	FMLD	Deep learning library	41	12

في هذا البحث قمنا بتسليط الضوء على اثنا عشر اتجاه بحثي حول الكشف عن الماسك الطبي على الوجه. حيث تم مراجعة مجموعات البيانات الصور الماسك الطبي على الوجه وتم دراسة خمس مجموعات بيانات وتحليل مجموعات البيانات هذه من مصادر

الصور، ووجد انه يمكن استخدام مجموعات البيانات معاً لإنشاء مجموعات بيانات أكبر جديدة لتحسين كفاءة نماذج الكشف عن الماسك الطبي على الوجه.

وبعد مراجعة سلسلة من طرق الكشف عن الماسك الطبي على الوجه تم تصنيفها إلى فئتين: الأساليب التقليدية والأساليب القائمة على تعلم الآلة. بالنسبة للطرق القائمة على تعلم الآلة، فإنها تمثل النسبة الأكبر استخداماً في الكشف عن الماسك الطبي على الوجه لأنها هي التقنيات السائدة والواحدة.

6-استنتاجات

نستنتج في هذا البحث ان الاستخدامات العديدة لتعلم الآلة يبين مدى أهمية تعلم الآلة والتعلم العميق لحل المشاكل التي تواجه المجتمعات، مثال على ذلك استخدامها لحل مشكلة انتشار COVID-19 الذي ينتقل عن طريق الرذاذ التنفسي، من خلال البحوث التي أجريت لحل هذه المشكلة استنتجنا انه يمكن بناء شبكات تعلم العميق وتدريبها لغرض الكشف عن مرتدي الماسك الطبي وغير مرتدي الماسك الطبي. وتبين ايضاً ان معظم الدراسات بهذا الخصوص تتألف من أربع مراحل رئيسية: جمع ومعالجة مسبقة للبيانات، بناء وتدريب النموذج، اختبار النموذج وتنفيذ النموذج مع بعض الميزات الفريدة لكل عمل. لوحظ أن النموذج ResNet50 و MobileNetV2 لديها أعلى دقة عند تدريبها مقارنة بالآخرين لمهام الكشف عن الماسك الطبي.

استنتجنا أيضاً أن دقة النموذج المصمم لغرض الكشف عن مرتدي الماسك الطبي او غير مرتدي الماسك الطبي تعتمد بصورة كبيرة على حجم مجموعة البيانات Datasets (عدد الصور) حيث يفضل ان تكون عدد صور التدريب كبيرة ويفضل ان تكون اكثر من 2000 صورة لكل حالة (وجوه ترتدي الماسك الطبي و وجوه لا ترتدي) أي بمعنى كلما زاد عدد صور بيانات التدريب فإن النموذج يقوم بالكشف بصورة كفاءة وتتم عملية تحسين الخطأ (تقليل الخطأ) وزيادة دقة النموذج مع إعطاء افضلية لمجموعة بيانات RWMFD.

كما لوحظ ان لغة Python الخيار المفضل لتحليلات البيانات والتعلم الآلي والذكاء الاصطناعي بفضل نظام المكتبات الواسع الذي يتيح التعامل مع البيانات وتحويلها ومعالجتها الذي يحتاج النظام الكشف عن الماسك الطبي، وأخيراً يمكن أن تكون مواصفات الحاسوب المستخدم مثل المعالج وحجم الذاكرة الوصول العشوائي RAM تأثير على سرعة بناء النموذج وكفاءته. وبالنهاية يفضل ان يستخدم خوارزميات تعلم الآلة ومنها خوارزميات التعلم العميق وخصوصاً الشبكة العصبية التلافيفية في تصميم نماذج الكشف عن الماسك الطبي على الوجه في الزمن الحقيقي نظراً لامتلاك الشبكة العصبية التلافيفية كفاءة عالية في حل المشاكل التي تعاني منها نماذج الكشف.

المصادر

1. WHO, 2020, "Listings of WHO's response to COVID-19 ".[cited 2021-10-Nov]. Available from: <https://www.who.int/news/item/29-06-2020-covid-timeline>.
2. Brooks JT, B.D., Noti JD, et al, 2021, "Maximizing Fit for Cloth and Medical Procedure Masks to Improve Performance and Reduce SARS-CoV-2 Transmission and Exposure, 2021". MMWR Morb Mortal Wkly Rep vol. 70, p. 254–257. Available: <http://dx.doi.org/10.15585/mmwr.mm7007e1>.
3. IBM Cloud Education, 2020, "Machine Learning".[cited 2021-01-Oct]. Available from: <https://www.ibm.com/cloud/learn/machine-learning>.
4. Langley, P. and H.A. Simon, 1995, "Applications of machine learning and rule induction". Commun. ACM, vol. 38(11), p. 54–64. Available: 10.1145/219717.219768.
5. Roy, P., 2021, "Examples of Machine Learning Applications in Real World".[cited 2022-03-jan]. Available from: <https://www.naukri.com/learning/articles/13-examples-of-machine-learning-applications-in-real-world>.

6. Sarker, I.H., 2021,"Machine Learning: Algorithms, Real-World Applications and Research Directions". SN Computer Science, vol. 2(3), p. 160. Available: 10.1007/s42979-021-00592-x.
7. Mathew, A., A. Arul, and S. Sivakumari, 2021, *Deep Learning Techniques: An Overview*, in Book *"Deep Learning Techniques: An Overview"*. p. 599-608. Available: 10.1007/978-981-15-3383-9_54.
8. Sarker, I.H., 2021,"Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions". SN Computer Science, vol. 2(6), p. 420. Available: 10.1007/s42979-021-00815-1.
9. Sarkar, D., R. Bali, and T. Sharma, 2018, *Practical Machine Learning with Python*, in Book *"Practical Machine Learning with Python"*. Apress, Berkeley, CA. p. 25-30. Available: <https://doi.org/10.1007/978-1-4842-3207-1>.
10. Negnevitsky, M., 2005,"Artificial Intelligence: A Guide to Intelligent Systems". Second ed. Addison-Wesley, p. 166-177.
11. Mani, K., DataDrivenInvestor, 2019, "What is a Neural Network?".[cited 2021-05- Oct]. Available from: <https://medium.datadriveninvestor.com/what-is-a-neural-network-9ca88b29f7cb>.
12. Oppermann, A., Towards Data Science, 2019, "What is Deep Learning and How does it work?".[cited 2021-05- Oct]. Available from: <https://towardsdatascience.com/what-is-deep-learning-and-how-does-it-work-2ce44bb692ac>.
13. Sewak, M., O'Reilly Online Learning, "Practical Convolutional Neural Networks".[cited 2022-01- Jan]. Available from: <https://www.oreilly.com/library/view/practical-convolutional-neural/9781788392303/5201f645-3f1f-4a24-8f9e-65023396e340.xhtml>.
14. Eda Kavlakoglu, P.M., IBM, 2020, "AI vs. Machine Learning vs. Deep Learning vs. Neural Networks: What's the Difference?".[cited 2022-01- Jan]. Available from: <https://www.ibm.com/cloud/blog/ai-vs-machine-learning-vs-deep-learning-vs-neural-networks>.
15. Sazli, M., 2006,"A brief review of feed-forward neural networks". Communications, Faculty Of Science, University of Ankara, vol. 50, p. 11-17. Available: 10.1501/0003168.
16. Upadhyay, Y., Towards Data Science, 2019, "Introduction to FeedForward Neural Networks".[cited 2021-20- Nov]. Available from: <https://towardsdatascience.com/feed-forward-neural-networks-c503faa46620>.
17. Du, K.L. and M.N.s. Swamy, 2014, *Recurrent Neural Networks*, in Book *"Recurrent Neural Networks"*. p. 337-353. Available: 10.1007/978-1-4471-5571-3_11.
18. Chatterjee, S., GreatLearning, 2020, "What is Recurrent Neural Network | Introduction of Recurrent Neural Network".[cited 2021- 02- Dec]. Available from: <https://www.scribbr.com/apacitation-generator/new/webpage/>.
19. Wani, M.A., et al., 2019, *Advances in Deep Learning*, in Book *"Advances in Deep Learning"*. Springer Singapore. p. 13. Available: <https://doi.org/10.1007/978-981-13-6794-6>.
20. LeCun, Y., et al., 1989,"Backpropagation Applied to Handwritten Zip Code Recognition". Neural Computation, vol. 1(4), p. 541-551. Available: 10.1162/neco.1989.1.4.541.
21. Karim, R., Towards Data Science, 2019, " CNN Architectures".[cited 2021-03- Dec]. Available from: <https://towardsdatascience.com/illustrated-10-cnn-architectures-95d78ace614d>.
22. IBM Cloud Education, 2020, "Convolutional Neural Networks".[cited 2021-25- Dec]. Available from: <https://www.ibm.com/cloud/learn/convolutional-neural-networks>.
23. Ghosh, A., et al., 2020, *Fundamental Concepts of Convolutional Neural Network*, in Book *"Fundamental Concepts of Convolutional Neural Network"*. Springer, Cham. p. 519-567. Available: 10.1007/978-3-030-32644-9_36.
24. Yamashita, R., et al., 2018,"Convolutional neural networks: an overview and application in radiology". Insights into Imaging, vol. 9(4), p. 611-629. Available: 10.1007/s13244-018-0639-9.

25. Saha, S., Towards Data Science, 2018, "A *Comprehensive Guide to Convolutional Neural Networks — the ELI5 way*".[cited 2021-28- Dec]. Available from: <https://towardsdatascience.com/a-comprehensive-guide-to-convolutional-neural-networks-the-eli5-way-3bd2b1164a53>.
26. kottarathil, p., kaggle, 2020, "*Face Mask Lite Dataset*".[cited 2021-06- Oct]. Available from: <https://www.kaggle.com/prasoonkottarathil/face-mask-lite-dataset>.
27. Sanjaya, S.A. and S.A. Rakhmawan, 2020,"Face Mask Detection Using MobileNetV2 in The Era of COVID-19 Pandemic". 2020 International Conference on Data Analytics for Business and Industry: Way Towards a Sustainable Economy (ICDABI), p. 1-5. Available: 10.1109/ICDABI51230.2020.9325631.
28. Sethi, S., M. Kathuria, and T. Kaushik, 2021,"Face mask detection using deep learning: An approach to reduce risk of Coronavirus spread". J. of Biomedical Informatics, vol. 120(C), p. 12. Available: 10.1016/j.jbi.2021.103848.
29. Shah, R., 2021,"Face mask detection using convolution neural network". ArXiv, vol. abs/2106.05728.
30. ArcGIS Develepe, "*How single-shot detector (SSD) works?*".[cited 2022-15- Feb]. Available from: <https://developers.arcgis.com/python/guide/how-ssd-works/>.
31. Talahua, J.S., et al., 2021,"Facial Recognition System for People with and without Face Mask in Times of the COVID-19 Pandemic". Sustainability, vol. 13(12), p. 6900. Available: doi:10.3390/su13126900.
32. Das, A., M.W. Ansari, and R. Basak, 2020,"Covid-19 Face Mask Detection Using TensorFlow, Keras and OpenCV". 2020 IEEE 17th India Council International Conference (INDICON), p. 1-5. Available: 10.1109/INDICON49873.2020.9342585.
33. Adusumalli, H., et al., 2021,"Face Mask Detection Using OpenCV". 2021 Third International Conference on Intelligent Communication Technologies and Virtual Mobile Networks (ICICV), p. 1304-1309. Available: 10.1109/ICICV50876.2021.9388375.
34. Suresh, K., M. Palangappa, and S. Bhuvan, 2021,"Face Mask Detection by using Optimistic Convolutional Neural Network". 2021 6th International Conference on Inventive Computation Technologies (ICICT), p. 1084-1089. Available: 10.1109/ICICT50816.2021.9358653.
35. Sreevani, P. and P.S. Devi, 2021,"Comparison of Deep Neural Network Models of Face Mask Detection in Multi-Angle Head Pose,". IJERT, vol. 10(09).
36. Sharma, V., 2020,"Face Mask Detection using YOLOv5 for COVID-19". Available: <http://hdl.handle.net/20.500.12680/m900nz55w>.
37. Yu, J. and W. Zhang, 2021,"Face Mask Wearing Detection Algorithm Based on Improved YOLO-v4". Sensors, vol. 21(9), p. 3263. Available: doi:10.3390/s21093263.
38. Mehendale, N., 2020,"Real-Time Face Mask Identification Using Facemasknet Deep Learning Network". SSRN. Available: <http://dx.doi.org/10.2139/ssrn.3663305>.
39. Qin, B. and D. Li, 2020,"Identifying Facemask-Wearing Condition Using Image Super-Resolution with Classification Network to Prevent COVID-19". Sensors, vol. 20(18), p. 5236. Available: doi:10.3390/s20185236.
40. Mandal, B., A. Okeukwu, and Y. Theis, 2021,"Masked face recognition using resnet-50". arXiv. Available: <https://doi.org/10.48550/arXiv.2104.08997>.
41. Solin , L., 2021,"Face mask wearing detection with neural network". Theseus.fi. Available: <https://urn.fi/URN:NBN:fi:amk-2021060113100>.