

Medical Images Classification Using Artificial Intelligence: A survey

Tasneem M. Hasan^{1*}, Jamal Salahaldeen Majeed Alneamy²

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

E-mail: ^{1*}tasneem.20csp8@student.uomosul.edu.iq, ²jamal_alneamy@uomosul.edu.iq

(Received May 17, 2022; Accepted August 02, 2022; Available online September 01, 2022)

DOI: [10.33899/edusj.2022.133358.1224](https://doi.org/10.33899/edusj.2022.133358.1224), © 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:

In recent years, the use of computing has increased along with medical skills, and this had impressive results in terms of classification and treatment, in addition to facilitating the matter of medical personnel. This was evident during the Corona pandemic, which infected millions around the world, which led to an almost complete closure to avoid the spread of the disease more and more. There is an urgent need for software tools to help classify the disease without the need to resort to doctors. The matter is not limited to the classification of corona disease, but it also extends to the expansion of the discovery of other diseases such as malaria, skin cancer and other diseases that afflict large numbers of people. Malaria is an infectious disease caused by the Plasmodium parasite, and according to some statistics from the World Health Organization, the total number of infections in 2019 reached about 228 million cases around the world. As for skin cancer, it is considered one of the serious diseases that affect humans because the skin plays a key role in protecting muscles and bones, and therefore cancer will affect all functions of the body.

Convolutional neural networks have made great strides in many intractable problems in image processing and classification, but their performance depends on their chosen hyperparameters which is a tedious task if done manually. Therefore, experts in the field of deep learning aspire to improve its performance sometimes by integrating it with other algorithms such as (PSO) Particle Swarm Optimization, (GWO) Gray Wolf Optimization, Genetic Algorithm GA or firefly. All of these algorithms gave different results than the others, that is, they gave different levels of performance

The aim of this research is to find a deep learning model that gives the best accuracy when classifying and we rely on Accuracy as a metric for evaluating the model.

Keywords: Convolutional Neural Networks, deep learning, image classification, malaria, covid_19, skin cancer.

تصنيف الصور الطبية باستخدام الذكاء الاصطناعي: دراسة

تسنيم محمد حسن^{1*}، جمال صلاح الدين مجيد النعيمي²

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

الخلاصة:

في السنوات الاخيرة الماضية زاد استخدام الحوسبة جنبا الى جنب مع المهارات الطبية، وكان لذلك نتائج مبهرة من ناحية التصنيف والمعالجة بالإضافة الى تسهيل امر الكوادر الطبية. بدى ذلك جليا اثناء جائحة كورونا، التي اصابت الملايين حول العالم

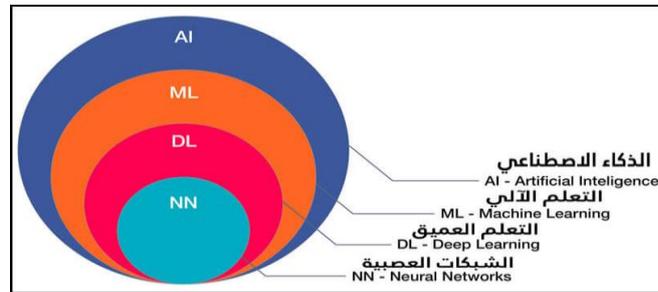
مما أدى إلى حالة إقبال شبه كامل لتجنب انتشار المرض أكثر فأكثر. أصبحت الحاجة ملحة لوجود أدوات برمجية تساعد في تصنيف المرض دون الحاجة للجوء إلى أطباء. لا يقتصر الأمر على تصنيف مرض كورونا إنما يتعدى إلى التوسع في اكتشاف أمراض أخرى مثل الملاريا وسرطان الجلد وغيره من الأمراض التي أصابت أعداد كبيرة من البشر. الملاريا يعتبر مرض معد يسببه طفيلي البلازموديوم، وحسب بعض إحصائيات منظمة الصحة العالمية، وصل إجمالي إصاباته إلى عام ٢٠١٩ حوالي ٢٢٨ مليون إصابة حول العالم. أما سرطان الجلد فيعتبر من الأمراض الخطيرة التي تصيب الإنسان لأن الجلد يلعب دور أساسي في حماية العضلات والعظام، بالتالي إصابته بالسرطان سيؤثر على جميع وظائف الجسم.

حققت الشبكات العصبية التلافيفية (CNN) إنجازات كبيرة في العديد من المشكلات المستعصية في معالجة الصور وتصنيفها، ولكن أدائها يعتمد على معلماتها الفائقة المختارة والتي تعبر مهمة شاقة إذا تمت بشكل يدوي. لذلك يطمح الخبراء في مجال التعلم العميق إلى تحسين أداءها أحياناً بدمجها مع خوارزميات أخرى مثل Particle Swarm Optimization (PSO) أو Gray Wolf Optimization (GWO) أو Genetic Algorithm GA أو Firefly وكل هذه الخوارزميات أعطت نتائج مختلفة عن الأخرى أي أنها أعطت مستويات مختلفة من الأداء. الهدف من هذا البحث إيجاد نموذج تعلم عميق بحيث يعطي أفضل دقة عند التصنيف ونعتمد على الدقة (Accuracy) كمقياس لتقييم النموذج.

الكلمات المفتاحية: الشبكات العصبية التلافيفية ، التعلم العميق ، تصنيف الصور ، الملاريا ، covid_19 ، سرطان الجلد.

1. المقدمة

يعتبر التعلم العميق تطور وامتداد لتعلم الآلة كما هو موضح في الشكل (1)، حين تعجز خوارزميات تعلم الآلة عن إنجاز بعض المهام المعقدة. حيث أن خوارزميات تعلم الآلة تتعلم من مجموعة بيانات مبسطة ولا تستطيع التعلم من مجموعة بيانات كبيرة أو معقدة، كاد التعلم العميق أن يتجاوز أقصى ما يمكن للآلات والبشر فعله باستعمال خوارزميات العصبية العميقة، هذه الأنواع من الخوارزميات تسمى الشبكات العصبية، وقد تجاوزت هذه الشبكات كل الشبكات السابقة لتصنيف الصور والنصوص والكلمات، وهي تدعم بعض أهم التطبيقات في العالم، مثل السيارات تلقائياً القيادة والترجمة الآتية وتصنيف الصور المختلفة لذلك تستخدم خوارزميات التعلم العميق عند تمييز الأصوات أو تمييز الوجه مثلاً. تتكون الخوارزميات من هيكل متعدد الطبقات من الشبكات العصبية الاصطناعية: طبقة ادخال_طبقتان أو أكثر خفية_طبقة اخراج. الطبقات الخفية هي المسؤولة عن المعالجة، لذلك تحتاج هذه الشبكات أقل مقدار من التدخل البشري في تحسين نتائج الخوارزمية. ولكن على الرغم من كل التطور الذي أحرزته هذه الشبكات العميقة، إلا أنها لازالت تتطور إلى يومنا هذا لأنها تحتاج الكثير من الوقت ومصادر حوسبة لأداء عملها. الشبكات العصبية التلافيفية هي نوع معين من الشبكات العصبية الاصطناعية التي تستخدم الإدراك الحسي، هي من نوع التعلم تحت الإشراف. هذه الشبكات قابلة للتطبيق على معالجة الصور ومعالجة اللغة الطبيعية.

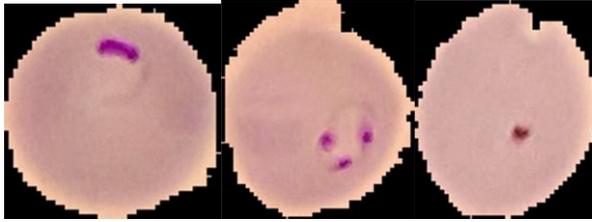


الشكل(1): يوضح علاقة الذكاء الاصطناعي بالتعلم العميق

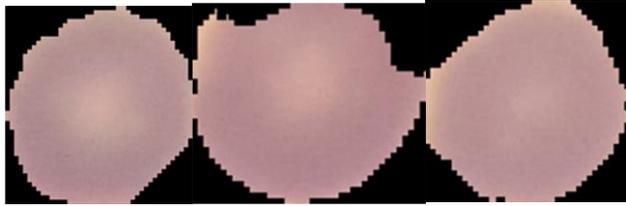
2. البيانات:

في هذا العمل تم استخدام 3 مجموعات بيانات متاحة في موقع (Kaggle)، يتم تقديمها للشبكة لتقوم بتقسيمها بشكل تلقائي الى 80 % بيانات تدريب و20% بيانات اختبار.

الأولى: هيا لمرض الملاريا متاحة للعامه وهيا من المعهد الوطني للصحة (NIH)، تتكون من 27000 صورة خلية، فيها عدد متساوي من الخلايا المتطفلة (المصابة) والخلايا بدون بلازموديوم (غير مصابة). الشكل(2) والشكل(3)

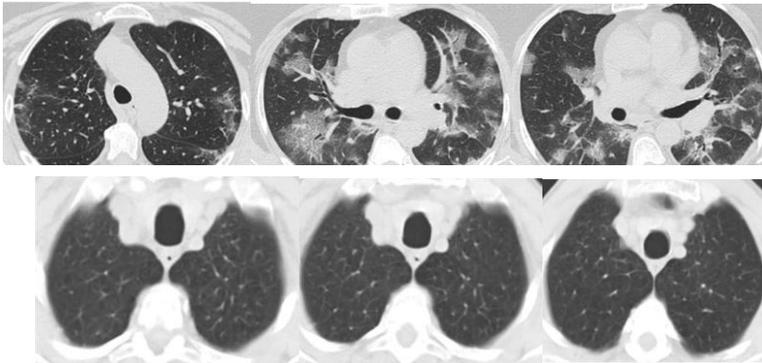


الشكل(2): يوضح نماذج من خلايا الدم المصابة



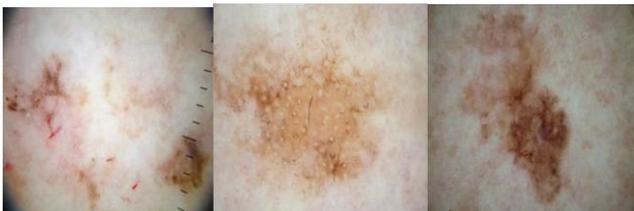
الشكل(3): يوضح نماذج من خلايا الدم غير المصابة بالملاريا

الثانية: هيا لصور CT-Scan لمرض كورونا تتكون من 1255 صورة مصابة و1229 صورة سليمة، الشكل (4) والشكل(5)



الشكل(5): يوضح نماذج من صور رئة اشخاص غير مصابين بالفايروس

الثالثة: هيا لسرطان الجلد وتتكون من 1800 صورة حميدة و1479 صورة مصابة بالسرطان. الشكل(6) والشكل(7)



الشكل (6): يوضح نماذج من صور اورام او بقع جلد سوطانية



الشكل (7): يوضح نماذج من صور لورام او بقع جلد حميدة

3. اعمال سابقة:

نحن في هذا البحث سنتناول 3 امراض شائعة على مستوى العالم وهيا: الملاريا، COVID_19، سرطان الجلد. وسنتطرق في هذا القسم الى الاعمال السابقة لكل مرض.

3.1 الملاريا: تعتبر الملاريا مرض معد يسببه طفيلي البلازموديوم. يتم حقن الطفيلي في الجسم بسبب لسعة بعوضة، هناك عدة أنواع من طفيلي البلازموديوم، من بينها المتصورة المنجلية والمتصورة النشيطة التي تحمل أكبر المخاطر، مع ذلك فإن التأثير الأكثر انتشارا هو للمتصورة المنجلية. في عام 2019 كان هناك 228 مليون حالة إصابة بالمرض في العالم [1]. وفقا لمنظمة الصحة العالمية، فإن هذا الطفيل يتمكن من الانتقال الى أكثر من مليوني شخص وهناك حوالي 300 الى 500 حالة إصابة سنوية بالملاريا [2] لذلك يتيح الفص المبكر عن عدوى الملاريا للمختصين الفرصة لوصف الادوية المناسبة في الوقت المناسب . تبدأ العدوى عندما يصاب الشخص بلدغة بعوضة الانوفيلية (Anopheles) تصيبه الطفيليات البلازمودية على شكل Sporozoites وهو بدوره يمر بسرعة في كبد الانسان ويتكاثر داخله بشكل سريع خلال 7-10 ايام، من ثم تنتقل عبر مجرى الدم وتستقر في الشعيرات الدموية في الرئة، ثم تنتقل هذه الاقسومات (merozoites) عن طريق خلايا الدم الحمراء وتتكاثر أكثر وتنقسم حتى تنفجر الخلية. اعراض المرض تبدأ بالحمى والغثيان والقيء والام في البطن وحتى الغيبوبة وإذا لم يتم علاجه بسرعة تؤدي إلى الوفاة. لذلك يعتبر التشخيص المبكر أمر بالغ الأهمية. هنالك عدة طرق لتشخيص الطفيلي ولكن اكثرها استخداما هو اخذ عينة دم للشخص المشتبه بإصابته وضعها تحت المجهر ولكن دقة التشخيص المجهرى تعتمد على دقة وخبرة اخصائي علم الامراض في هذا الموضوع. وهذا قد يؤدي الى تشخيص غير صحيح بالتالي قد يؤدي إلى اعطاء علاج غير صحيح [3]. بسبب هذا العيب تم اقتراح العديد من النماذج المحوسبة للكشف عن الملاريا يعتمد اغلبها على صور مسحات الدم. ويمكن ان تكون هذه النماذج مفيدة جدا لأخصائي الملاريا.

حاولت البحوث السابقة اتباع تقنيات مختلفة لمعالجة الصور عن طريق التعلم الآلي (ML) لتصنيف كريات الدم الحمراء المصابة بالملاريا من صور مسحة الدم [4] أي طريقة لتشخيص الملاريا القائمة في معالجة الصور تتبع خمس مراحل وظيفية وهي: اكتساب الصور، المعالجة المسبقة على الصورة، اقتطاع كرية دم الحمراء، استخلاص الخواص ثم التصنيف [5] و يمثل احد اكبر التحديات في صياغة الميزات التقليدية استخراج الخصائص وتطبيق الخوارزمية المناسبة لتعيين الميزات المستخرجة للتعرف على صور الملاريا المصابة [6] هذه العملية مجهددة وصعبة، لأن المصمم يجب يستخدم الخوارزمية الفعالة لاكتشاف رؤى مفيدة من صور الملاريا، كشفت الدراسات الحديثة أن نماذج التعلم العميق (DL) قادرة على تعلم المعرفة مثل البشر من خلال التجربة. الشبكة

العصبية التلافيفية (CNN) هي احدى فئات مناهج التعلم العميق، انها تتفوق في تصنيف الصور وتحاكي بنية الشبكة العصبية الاصطناعية (ANN) مثل الذكاء البشر

على الرغم من ان LeNet_5 (وهي شبكة CNN الرائدة بواسطة LeCun وآخرون [8]) قد حلت مشكلة التعرف على الصور منذ عقود. لم يكن الأمر كذلك حتى حصلت AlexNet (وهي تطبيق GPU لشبكة CNN العميقة [9]) على نسبة خطأ مثيرة للإعجاب 15.3% اي اقل بنسبة 10.8 عن سابقتها، في تحدي Image Net 2012 حظيت شبكة CNN باهتمام متجدد من الباحثين، وبتشجيع من نجاحها تم اختراع العديد من شبكات CNN مثل ResNet [10] و VGG [11] و googleNet [12] و DenseNet [13]. ان الأداء الرائع لشبكات CNN هذه لا يرجع فقط الى التصميمات المتميزة لهياكل شبكات CNN التي قام بها المؤلفون بل يرجع ايضا إلى القيم المختارة بعناية للمعلمات الفائقة (Hyper parameters). لذلك، فإن اختيار القيم المناسبة للمعلمات الفائقة يعتبر امر صعب للغاية لأنه لا يعتمد فقط على مستوى خبرة الشخص فحسب ولكن ايضا على قدرة تعلمه من كل جولة من تجارب اختبار القيم.

خلال العقود الأخيرة الماضية، كان هناك قدر كبير من البحوث تستخدم خوارزميات الحوسبة لحلول فعالة ومفيدة للمسائل الطبية، وبالتأكيد، كان لمرض الملاريا نصيب من هذه البحوث. على سبيل المثال، J.A. Alkrimi [14] قام بالمعالجة المسبقة للصور واستخراج الميزات، والتي تم تخزينها في ملف اكسل وتمت عليها العديد من المعالجات مثل ازالة الضوضاء وتنظيف البيانات وازالة التكرارات وغيرها. ثم تم استخدام خوارزميتين للتصنيف هما ANN, SVM, حيث أعطت الأولى دقة تقارب 94.1 والثانية 92.3 على التوالي

Mehedi وآخرون [15] قدم ورقة بحثية هدفها هو البحث عن كيفية الاستفادة من خوارزميات التعلم العميق. اظهر مدى عمق بنية التعلم مثل شبكة (CNN) ممكن ان تكون مفيدة في اكتشاف الملاريا في الوقت الحقيقي بشكل فعال باستخدام تطبيق الهاتف المحمول. قام بتقييم أداء نموذج (CNN) باستخدام محسن الهبوط التدرج العشوائي الدوري (SGD).

تمت معالجة العديد من تقنيات المعالجة المسبقة لصور مسحة الدم لتحسين الجودة المكانية للصورة مثل May وآخرون [16] استخدم مرشح Median لتقليل ضوضاء النبض واقترح ايضا مرشح Wiener لتقليل الضوضاء المضافة لعكس ضبابية الصور. Arco وآخرون [17] استخدم مرشح Gaussian لإزالة الضوضاء الغوسية بشكل فعال من الصور.

أيضا من الابحاث التي تم إجراؤها في تشخيص الملاريا Dhanya Bibin وآخرون [18] حيث انهم قدمو نموذج باستخدام Deep Belief Network (DBN) بحيث ان الشبكة تكون مدربة مسبقا بواسطة التكدس المقيد Boltzmann machine باستخدام مبدأ التباين المختلف.

Narayanan وآخرون [19] درس مناهج التعلم الالي والتعلم العميق المختلفة للكشف عن الملاريا، حيث يطبق ثبات اللون ويعيد تشكيل جميع الصور مكانيا الى حجم معين بالاعتماد على معمارية التصنيف المطبقة، حيث اقترح بنية (CNN) سريعة للتصنيف. وتم مقارنة أداء هذا النموذج مع بنى الشبكات الراسخة مثل AlexNet, ResNet, VGG-16, DenseNet. بالإضافة الى دراسة أداء نموذج bag-of-features مع (SVM) من اجل التصنيف. حصل على دقة اجمالية تصل الى (96.7) %.

Gautham وآخرون [20] قدم نموذج جديد ومتميز للتعلم الالي يعتمد على الشبكة العصبية التلافيفية (CNN) التي تصنف وتتنبأ تلقائيا بالخلايا المصابة. يتم فيه استخدام طبقة التحقق ذات 10 تلافيف لفهم معلمات الخلية. يتم مقارنة 3 طرازات من (CNN) بناء على دقتها Basic CNN, VGG-19 Frozen CNN, VGG-19 Fine-tuned CNN، حيث يتم التوصل الى النموذج ذو الدقة الأعلى. حيث تم التوصل الى ان VGG-19 Fine-tuned CNN هي الأعلى دقة.

Divyansh وآخرون [21] نموذج شبكة عصبية تتكون من ثلاث طبقات تلافيفية وطبقة متصلة بالكامل لكل طبقة، النموذج الذي قدموه هو عبارة عن سلسلة من طبقات تلافيفية متعددة تحتوي على المرشحات المختلفة داخل هذه الطبقات، مما ينتج عنه دقة جيدة حسب الموارد المتاحة. حيث توصلت الشبكة الى دقة 95%.

اما Feng Yang واخرون [21] طور اول نموذج تعلم عميق يتمكن من اكتشاف الملايا من صور مسحات الدم الكثيفة ويمكن تشغيله على الهواتف الذكية. حيث استخدم (IGMS) والذي نفذ فحص اسرع ويحدد الطفيليات المرشحة أي التي ممكن ان تكون مصابة، تأتي بعدها الخطوة الثانية، وهو تطبيق نموذج (CNN) لتصنيف الخلية(المرشحة) هيا مصابة ام لا. حصل على دقة (93.46%).

3.2_COVID_19: انتشر فيروس كورونا المستجد (COVID-2019) الذي ظهر لأول مرة في مدينة وهان الصينية في ديسمبر 2019 بسرعة في جميع أنحاء العالم وأصبح وباءً عالمياً. حيث ان العالم بأسره يشهد حالة من الإغلاق بسبب هذه الجائحة، قد تسبب في آثار مدمرة على كل جوانب الحياة اليومية والصحة العامة والاقتصاد العالمي. لذلك من الأهمية اكتشاف الحالات الإيجابية في أقرب وقت ممكن لمنع انتشار المزيد من هذا الوباء وعلاج المرضى المصابين بأسرع وقت ممكن. يصيب فيروس كورونا الجديد بعد دخوله من خلال الجهاز التنفسي للإنسان رئتي الشخص بشكل خطير، مما يتسبب في ظروف حادة شبيهة بالالتهاب الرئوي المعروف. تمتلئ الرئتان بالسوائل، فتُصاب بالالتهاب وتحدث بقع تسمى ب (Ground Glass Opacity). نظراً لبذل الكثير من الجهود لإيجاد حل فعال لإيقاف هذه الجائحة، إلا أن الطريقة الفعالة الوحيدة للحماية حتى اليوم هي التباعد الاجتماعي وإغلاق المدن المختلفة بين بعضها البعض. ومع ذلك، فإن الجانب المظلم من الإغلاق هو أنه يؤثر على الناتج المحلي الإجمالي للدولة وله أيضاً تأثير نفسي سلبي على صحة وعقل الناس. يتزايد عدد المصابين بالفيروس بشكل كبير في جميع أنحاء العالم. هناك دول متضررة بشكل كبير جداً مثل الولايات المتحدة الأمريكية وإيطاليا وإسبانيا الصين بالتالي أثر بشكل سلبي على الاقتصاد العالمي. ريتشارد بالدوين أستاذ علوم الاقتصاد الدولي في معهد الدراسات العليا في جنيف قال: "هذا الفيروس معدي اقتصادياً كما هو معدي طبيياً" [22].

في الوقت الحالي تعتبر إجراءات الكشف والفحص الفعالة إلى جانب الإجراءات الطبية المناسبة والسريعة، هي حاجة الساعة. يعد اختبار تفاعل البوليميراز المتسلسل للنسخ العكسي (RT-PCR) تقنية فحص مفيدة لـ COVID_19 والأكثر شيوعاً. هذه الطريقة معقدة وتستغرق وقتاً طويلاً أحياناً تستغرق 48 ساعة ويمكن أكثر من ذلك إذا ازدادت شدة الوباء، ولكن دقتها تبلغ حوالي 63% [23]. مع إجراءات الاختبار اليدوي المعقدة ونقص أدوات الاختبار، يتفاعل المصابون مع العالم الصحي مما يؤدي إلى ارتفاع أسي في الحالات النشطة [24]. الأعراض الطبية لعدوى COVID-19 الشديدة هي الالتهاب الرئوي القصي، الذي يسبب الحمى والسعال وضيق التنفس والالتهاب الرئوي [24-27]. هناك الكثير من البحوث التي سعت الى الاستفادة من التعلم العميق في تصنيف و التعرف على فيروس كورونا، من ضمنها البحث الذي تقدم به Maad M. Mijwil [28] حيث قام بتطبيق تقنيات التعلم الآلي (Random forest ، Support Vector Machine ، Naïve Bayes Logistic Regression). بحسب تجربته توصل ان تقنية آلة الناقل الداعمة كانت افضلهم اداء بدقة وصلت الى 91.8%.

Tulin Ozturk واخرون [29] قدم نمودجا جديدا للكشف التلقائي عن COVID-19 باستخدام صور الأشعة السينية الخام للصدر. تم تطوير النموذج المقترح لتوفير تشخيصات دقيقة للتصنيف الثنائي (COVID مقابل No-Findings) والتصنيف متعدد الفئات (COVID مقابل عدم وجود نتائج مقابل الالتهاب الرئوي). أنتج نمودجنا دقة تصنيف 98.08% للفئات الثنائية و 87.02% للحالات متعددة الفئات. تم استخدام نموذج DarkNet في هذه الدراسة كمصنف لنظام اكتشاف الأشياء في الوقت الفعلي الذي تنظر إليه مرة واحدة فقط (YOLO). قام بتنفيذ 17 طبقة تلافيفية وأدخل ترشيحاً مختلفاً على كل طبقة. والنموذج متوفر للجميع على ال Github.

Shervin Minaee واخرون [30] استخدم 5000 صور اشعة الصدر، استخدم تعلم النقل على مجموعة فرعية(2000)صورة ثم قام بتقييم اربع شبكات عصبية تلافيفية على ما تبقى من الصور(3000). الشبكات هيا: ResNet18 و ResNet50 و SqueezeNet و DenseNet-121. معظمها حققت معدل حساسية 98% (±3%). قدم أيضاً منحني خاصة تشغيل المستقبل

(ROC) ومنحنى الاسترجاع الدقيق والتنبؤ المتوسط ومصفوفة الارتباك لكل نموذج. استخدم أيضًا تقنية لإنشاء خرائط حرارة لمناطق الرئة المحتمل إصابتها بفيروس COVID-19 وإظهار أن خرائط الحرارة التي تم إنشاؤها تحتوي على معظم المناطق المصابة التي تم شرحها بواسطة أخصائي الأشعة المعتمد.

Harsh Panwar وآخرون [31] اقترح طريقة التعلم العميق القائمة على الشبكة العصبية nCOVnet ، وهي طريقة بديلة للفحص السريع يمكن استخدامها للكشف عن COVID-19 من خلال تحليل الأشعة السينية للمرضى.

Soumya Ranjan Nayak وآخرون [32] اقترح آلية بمساعدة DL باستخدام صور الأشعة السينية للتشخيص المبكر لعدوى COVID-19، تقوم بتقييم فعالية ثمانية نماذج شبكة عصبية تلافيفية (CNN) مُدرية مسبقًا مثل AlexNet و VGG-16 و GoogleNet و MobileNet-V2 و SqueezeNet و ResNet-34 و ResNet-50 و Inception-V3 لتصنيف COVID-19 من الحالات العادية. حيث تمت المقارنة بين هذه النماذج من خلال النظر في العديد من العوامل المهمة مثل حجم الدفعة، ومعدل التعلم، وعدد الـ epochs ، وأنواع الـ optimizers بهدف العثور على النموذج الأنسب. كانت النتيجة، ان أفضل أداء توصل اليه كان بواسطة ResNet-34 بدقة 98.33%.

Loveleen Gaur وآخرون [33] قدم في دراسته حلاً عملياً لاكتشاف COVID-19 من الأشعة السينية للصدر مع التمييز بين تلك العادية والمتأثرة بالالتهاب الرئوي الفيروسي عبر الشبكات العصبية الالتفافية العميقة (CNN). حيث تم تقييم ثلاثة نماذج CNN مدرية مسبقًا (EfcientNetB0 و VGG16 و InceptionV3) من خلال نقل التعلم. الأساس المنطقي لاختيار هذه النماذج المحددة هو توازنها في الدقة والكفاءة مع عدد أقل من المعلمات المناسبة للتطبيقات المتقدمة.

M.K. Pandit وآخرون [34] استخدم مجموعة البيانات تحتوي على 1428 صورة شعاعية للصدر، طبق عليها نموذج VGG-16 المدرب مسبقًا لمهام التصنيف، تم استخدام التعلم بالنقل مع الضبط الدقيق في هذه الدراسة لتدريب الشبكة على صور شعاعية صغيرة نسبيًا للصدر بشكل فعال، أظهرت التجارب الأولية أن النموذج حقق نتائج واعدة ويمكن استخدامه بشكل كبير لتسريع اكتشاف COVID-19 بدقة بلغت 96% و 92.5% في التصنيف الثنائي و المتعدد على التوالي.

3.3 سرطان الجلد: السرطان هو انقسام غير متحكم فيه للخلايا المرضية التي يمكن أن تغزو أقسامًا بعيدة من الجسم. يمكن للجلد أن يلعب دورًا مهمًا في جسم الإنسان من خلال حماية العضلات والعظام في جميع أجزاء الجسم. إذا تباعدت وظائف الجلد قليلاً، فإن بنية الجسم بأكملها تصبح مضطربة، مما سيؤثر على جميع وظائف الجسم الأساسية [35]. سرطان الجلد يكون خبيث أو حميد. الورم الميلانيني الحميد هو ببساطة ظهور الشامه على الجلد. الورم الميلانيني الخبيث هو ظهور التقرحات التي تسبب النزيف. الورم الميلانيني الخبيث هو من أخطر أنواع السرطانات يعتبر من السرطانات المميتة. ومع ذلك يمكن علاج معظم سرطانات الجلد في المراحل الأولية. لذا فإن الكشف المبكر عن سرطان الجلد يمكن أن ينقذ المرضى. ينشأ النمو السرطاني في آفة الجلد المصطبغة. تشخيص الورم الميلانيني صعب ويحتاج إلى أخذ عينات وفحوصات مخبرية. يمكن أن ينتشر الميلانوما إلى جميع أجزاء الجسم من خلال الجهاز اللمفاوي أو الدم. غالبًا ما يتسبب أخذ العينات المخبرية في حدوث التهاب أو حتى انتشار المرض. لذلك، كان هناك دائمًا نقص في الأساليب الأقل خطورة بالإضافة الى انها تستغرق وقتًا طويلاً. يمكن للتشخيص المستند إلى الكمبيوتر تحسين سرعة تشخيص سرطان الجلد والذي يعمل وفقًا لأعراض المرض. إن أوجه التشابه بين الآفات الجلدية جعل تشخيص الخلايا الخبيثة مهمة صعبة. ولكن هناك بعض الأعراض الفريدة لسرطان الجلد مثل: عدم التناظر وعدم انتظام الحدود تقلب اللون والقطر. هذه المعلمات معروفة بإسم معلمات ABCD. معلمات ABCD. عدم التناظر، عدم انتظام الحدود، اللون، القطر. عدم التناظر هو أن نصف الورم لا يتطابق مع النصف الآخر. عدم انتظام الحدود هو عدم انتظام الصور. تغير شدة اللون

في المنطقة المصابة غير منتظم. يزيد قطر الورم الميلانيني الخبيث عن 6 مم [35]. قدم الباحثون الكثير من الاقتراحات لإكتشاف سرطان الجلد باستخدام تقنيات الذكاء الاصطناعي، لإعطاء النتائج بشكل ادق وبوقت اسرع.

Maad M. Mijwil [36] استخدم ثلاث بنى مختلفة للشبكة العصبية التلافيفية (ConvNet) وهي (InceptionV3) و ResNet و (VGG19) ، واثبت ان InceptionV3 هي الأفضل في تصنيف هذا المرض بدقة تصل الى 86.90%.

Abdul Jaleel وآخرون [37] استخدم منهجية تشخيص مختلفة أي استخدم تقنيات معالجة الصور والذكاء الاصطناعي. يتم التقاط الصورة واخضاعها ل pre_processing المختلفة لإزالة الضوضاء وتحسين الصورة. ثم تخضع الصورة للتجزئة باستخدام Thresholding. يتم بعدها استخراج الميزات باستخدام تقنية استخراج الميزات 2D Wavelet Transform method_ يتم إعطاء هذه الميزات كعقد إدخال للشبكة العصبية. تستخدم الشبكة العصبية العكسية (BPN) لغرض التصنيف.

Uzma Bano Ansari وآخرون [38] أيضا اخضع الصورة للمعالجة المسبقة بالطريقة السابقة ثم التجزئة باستخدام ال Thresholding، استخراج بعض ميزات الصورة باستخدام منهجية GLCM. ثم يتم إعطاء هذه الميزات كمدخلات للمصنف. استخدم (SVM) لغرض التصنيف. يصنف الصورة المعينة إلى سرطانية أو غير سرطانية.

A. Murugan وآخرون [39] استخدم طريقة watershed segmentation method للتجزئة. تخضع الأجزاء المستخرجة لاستخراج الميزة. الميزات المستخرجة هي الشكل وقاعدة ABCD و GLCM. ثم يتم استخدام الميزات المستخرجة للتصنيف. المصنفات هي (k Nearest Neighbour) و Random Forest و SVM (Support Vector Machine). من بين المصنفات المختلفة ، قدم المصنف SVM نتائج أفضل لتصنيف الآفات الجلدية.

Ni Zhang وآخرون [40] اقترح طريقة جديدة تعتمد على معالجة الصور للكشف المبكر عن سرطان الجلد. تستخدم الطريقة شبكة عصبية تلافيفية مثالية (CNN) لهذا الغرض. تم استخدام خوارزمية تحسين الحوت لتحسين شبكة CNN.

Md. Muzahidul Islam وآخرون [41] استخدمنا العديد من خوارزميات الشبكة العصبية وقمنا بتحليل أدائها لاكتشاف خمسة أمراض جلدية رئيسية، CNN وباستخدام Keras Sequential API قام ببناء نموذج جديد للحصول على دقة تصل إلى حوالي 80%. ثم للمقارنة ولزيادة الدقة أيضًا ، استخدم البنى التي تستخدم البيانات المدربة مسبقًا. يتضمن نموذج تعلم النقل هذا VGG11 و RESNET50 و DENSENET121. من بين الخوارزميات المستخدمة في النماذج المقترحة ، تحقق هندسة resnet أعلى دقة بنسبة 90%.

Ibrahim AlShourbaji وآخرون [42] استخدم الشبكة العصبية التلافيفية (CNN) لتحديد سرطانات الجلد ، وتوضح النتائج الملحوظة أن طريقة CNN يمكن أن تحدد بشكل فعال سرطان الجلد والحالات الحميدة من صور الأشعة السينية.

باختصار تم استخدام العديد من خوارزميات التعلم العميق ومعالجة الصور image processing لتصنيف الصور الطبية المختلفة، وقد ساعدت هذه المساهمات الكوادر الطبية المختلفة في التشخيص. كل طريقة كانت لها ميزات تختلف عن الأخرى ونتائج مختلفة حسب ما رأى مؤلفوها. يوضح الجدول (1) خلاصة الاعمال السابقة والاليات والبيانات المستخدمة، مع النتائج المستحصلة من كل الية.

جدول (1) خلاصة الاعمال السابقة

النتائج	الالية المستخدمة	تفاصيل البيانات المستخدمة	المرض
Accuracy=94.1	Image preprocessing, feature extraction, ANN,SVM	1000صورة مسح دم	ملاريا
Accuracy=97.3	CNN(4convolution استخدم blocks),SGD optimizer.	صور مسح الدم، عددها 27,558صورة	ملاريا
F-score=89.66 Sensitivity=97.60 Specificity=95.92 Accuracy=96.21	DBN, Restricted Boltzmann Machin,	4100 صورة مسح دم تم التقاطها بكاميرة CANON A60.	ملاريا
Accuracy=96.7	Fast CNN,	صور مسح الدم، عددها 27,558صورة	ملاريا
VGG-19 Fine-tuned CNN is the best performance have Accuracy=99%	CNN, then compare it's performance with VGG-19 Frozen CNN, VGG-19 Fine-tuned CNN	صور مسح الدم، عددها 27,558صورة	ملاريا
Accuracy=95	CNN	صور مسح الدم، عددها 17,460 صورة.	ملاريا
Sensitivity=92.59 Specificity=94.33 Accuracy=93.46 AUC=98.39	IGMS for fast screening. CNN for classification	صور مسح دم كثيفة عددها 1819.	ملاريا
Accuracy=95	Random Forest, Logistic Regression, Naïve Bayes, Support Vector Machine	تقريبا 1400صورة اشعة رئة	COVID_19
Accuracy: binary classes=98.08 multi-class=87.02	تطوير نموذج DarkNet ليصبح DarkCovidNet ب19طبقة convoluion	1127 صورة اشعة صدر مصنفة الى مصاب، غير مصاب، التهاب رئوي.	COVID_19
Sensitivity for all=98 ± 2.7 Specificity for ResNet18= 90.7 Specificity for ResNet50=89.6 Specificityof SqueezeNet=92.9 Specificity of DenseNet-121=75.1	Transfer learning: ResNet18, ResNet50, SqueezeNet, and DenseNet-121,	5000 صورة اشعة صدر	COVID_19

Accuracy=88.10	يستخدم nCOVnet يحتوي 24 طبقة، يعمل على نقل التعلم من VGG16	5863 صورة اشعة صدر مصنفة الى 4 فئات: مصاب، سليم، الالتهاب الرئوي الجرثومي و الالتهاب الرئوي الفيروسي.	COVID_19
Accuracy= 92.93 Sensitivity= 94.79 Specifcity= 0.95 F1 scores= 0.88	Transfer learning: Inceptionv3,VGG16, EfcientNetB0, the last have best performance.	3106 صورة اشعة صدر	COVID_19
Accuracy: 96 for binary classification 92.5 for multi classification	Transfer learning: VGG16	1428 صورة اشعة صدر، وبواسطة تقنية زيادة البيانات التي تولد المزيد من العينات بالتناوب في خمس زوايا مختلفة.	COVID_19
Accuracy=86.90	InceptionV3, ResNet, and VGG19	24000 صورة جلد	سرطان الجلد
_____	Image processing: Segmentation, 2D Wavelet Transform Classification: BPN	_____	سرطان الجلد
Accuracy =95%	Pre- processing: Median filter, Feature Extraction: GLCM Classifier: SVM.	تم الاختبار على 20 صورة	سرطان الجلد
For SVM(the best) Accuracy= 89.43 Sensitivity= 91.15 Specifcity= 87.71	watershed segmentation. Feature Extraction: GLCM. Classifiers:, Random Forest, kNN, SVM(the last have the better).	_____	سرطان الجلد
Accuracy about 95% Sensitivity about 98% Specifcity about 97%	CNN, WOA(whale optimization algorithm)	22000 صورة مناظير للجلد تتضمن مصابة بالسرطان و يقع او اورام حميدة	سرطان الجلد
ResNet50 have the best Accuracy=90%	CNN Transfer learning: ResNet50, DenseNet 121, VGG11	10015 صورة مناظير الجلد	سرطان الجلد
Accuracy =82.4	CNN	3297 صورة مناظير للجلد	سرطان الجلد

4. الاستنتاجات:

نظرا لكثرة انتشار الأمراض والابوة في وقتنا الحالي أصبح من الضروري استخدام الحوسبة في تصنيف واكتشاف هذه الامراض لتقليل العبء على الكوادر الطبية، خاصة في ظل جائحة كورونا، فهو وباء عالمي واعداد المصابين في تزايد مستمر. حيث تجاوزت اعداد إصابات كورونا حول العالم حتى اليوم تقريبا (462 مليون إصابة)، اما إصابات ملاريا فقد وصلت الى (241 مليون إصابة خلال عام 2020 فقط)، وبلغت اعداد الوفيات بسبب سرطان الجلد (1,20 مليون حالة) في العالم. هذه الاحصائيات حسب منظمة الصحة العالمية (WHO).

أظهرت الدراسات السابقة على مجموعات البيانات للأمراض (ملاريا، كوفيد-19، سرطان الجلد)، ان الدور الريادي في اكتشاف هذه الامراض هو لشبكة CNN (الشبكات العصبية التلافيفية). بالنسبة للطرق المستخدمة في اكتشاف الملاريا المذكورة في هذا البحث، فإن أفضل أداء كان ل VGG-19 Fine-tuned CNN حيث وصلت الى دقة تقارب ال 99%. اما الطرق المستخدمة في اكتشاف مرض كوفيد-19 كان أفضل أداء لنموذج DarkCovidNet والذي اعطى دقة تقارب ال 98%. اما بالنسبة للأعمال السابقة لاكتشاف سرطان الجلد، فإن نموذج CNN المحسن ب (WOA (whale optimization algorithm حقق أفضل أداء وصل الى دقة تقارب 95%. لذلك يوصى باستخدام نماذج CNN المهجنة مع خوارزميات السرب، لبناء نموذج يمتاز بالدقة والسرعة العالية لتشخيص الحالات المرضية التي هي محور البحث.

المصادر

- [1] World malaria report 2019. Geneva: world Health Organization; 2019.
- [2] M. Aregawi, R. Cibulskis, M. Otten, R. Williams and C. Dye, "World malaria report 2008", 2008.
- [3] K. Mitiku, G. Mengistu and B. Gelaw, "The reliability of blood film examination for malaria at the peripheral health unit", Ethiopian J. Health Develop., vol. 17, pp.197-204, 2004.
- [4] Savkare SS, Narote SP (2015) Automated system for malaria parasite identification. International Conference on Communication, Information & Computing Technology (ICCICT), Mumbai, pp 1-4.
- [5] Das DK, Maiti AK, Chakraborty C (2015) Automated system for characterization and classification of malaria-infected stages using light microscopic images of thin blood smears. J Microsc 257(3):238-252.
- [6] Dong Y et al (2017) Evaluations of deep convolutional neural networks for automatic identification of malaria infected cells. IEEE EMBS International Conference on Biomedical & Health Informatics (BHI), Orlando, pp 101-104.
- [7] Makkapati VV, Rao RM (2011) Ontology-based malaria parasite stage and species identification from peripheral blood smear images. Ann Int Conf IEEE Eng Med Biol Soc:6138-614.
- [8] Y. Lecun, L. Bottou, Y. Bengio, P. Haffner, Gradient-based learning applied to document recognition, Proceedings of the IEEE (1998) 2278-2324.
- [9] K. Alex, S. Ilya, H. G. E., Imagenet classification with deep convolutional neural networks, in: Advances in Neural Information Processing Systems, 2012, pp.1097-1105.
- [10] H. Kaiming, Z. Xiangyu, R. Shaoqing, S. Jian, Deep residual learning for image recognition, in: IEEE Conference on Computer Vision and Pattern Recognition, 2016, pp. 770-778.
- [11] K. Simonyan, A. Zisserman, Very deep convolutional networks for large-scale image recognition, in: International Conference on Learning Representations, 2015.
- [12] S. Christian, L. Wei, J. Yangqing, S. Pierre, R. Scott, A. Dragomir, E. Dumitru, V. Vincent, R. Andrew, Going deeper with convolutions, in: IEEE Conference on Computer Vision and Pattern Recognition, 2015, pp. 1-9.

- [13] G. Huang, Z. Liu, L. van der Maaten, K. Q. Weinberger, Densely connected convolutional networks, in: IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017, pp. 2261–2269.
- [14] J. A. Alkrimi, Sh. A. Toma, R. S. Mohammed, L. E. George, Using Knowledge Discovery to Enhance Classification Techniques for Detect Malaria-Infected Red Blood Cells, *Int. J. Sc. Res. in Network Security and Communication*, 1/Feb/2020.
- [15] M. Masud, H. Alhumyani, Sultan S. Alshamrani, O. Cheikhrouhou, S. Ibrahim, G. Muhammad, M. Sh. Hossain and M. Shorfuzzaman, Leveraging Deep Learning Techniques for Malaria Parasite Detection Using Mobile Application, in: *Wireless Communications and Mobile Computing*, Volume 2020, Article ID 8895429, 15 pages.
- [16] May Z, Mohd Aziz SSA, Salamat R (2013) Automated quantification and classification of malaria parasites in thin blood smears. *IEEE International Conference on Signal and Image Processing Applications*, Melaka, pp 369–373.
- [17] Arco JE, Gorriz JM, Ramírez J, Alvarez I, Puntonet CG (2015) Digital image analysis for automatic enumeration of malaria parasites using morphological operations. *Expert Syst Appl* 42:3041–3047.
- [18] D.Bibin, M.S. NAIR, P. Punitha, Malaria Parasite Detection From Peripheral Blood Smear Images Using Deep Belief Networks, in: *IEEEAccess*, vol.5, pp. 9099_9108, 2017.
- [19] Barath Narayanan Narayanan, Redha Ali, Russell C. Hardie, "Performance analysis of machine learning and deep learning architectures for malaria detection on cell images," *Proc. SPIE* 11139, Applications of Machine Learning, 111390W (6 September 2019).
- [20] Gautham Shekar·S. Revathy ·Ediga Karthick Goud...Malaria Detection using Deep Learning, *Proceedings of the Fourth International Conference on Trends in Electronics and Informatics (ICOEI 2020)* IEEE Xplore Part Number: CFP20J32-ART; ISBN: 978-1-7281-5518-0.
- [21] Divyansh Shah, K. Kawale, M. Shah, S. Randive, R. Mapari, Malaria Parasite Detection Using Deep Learning, in: *Proceedings of the International Conference on Intelligent Computing and Control Systems (ICICCS 2020)* IEEE Xplore Part. Number:CFP20K74-ART; ISBN: 978-1-7281-4876-2.
- [21] Feng Yang, M. Poostchi, Hang Yu, Zhou Zhou , K. Silamut, Jian Yu, Richard J. Maude, S. Jaeger , and S. Antani, Deep Learning for Smartphone-Based Malaria Parasite Detection in Thick Blood Smears, in: *IEEE JOURNAL OF BIOMEDICAL AND HEALTH INFORMATICS*, VOL. 24, NO. 5, MAY 2020.
- [22] Pandemic A.E.. Coronavirus disease (covid-2019) r&d. <https://foreignpolicy.com/2020/03/09/coronavirus-economic-pandemic-impact-recession/>Last accessed on Mar 2020; 2020.
- [23] Wang, D., Hu, B., Hu, C., Zhu, F., Liu, X., Zhang, J., et al.: Clinical characteristic of 138 hospitalized patients with 2019 novel coronavirus–infected pneumonia in Wuhan, China. *JAMA* 323(11), 1061–1069 (2020).
- [24] Shorfuzzaman, M., Hossain, M.S., Alhamid, M.F.: Towards the sustainable development of smart cities through mass video surveillance: a response to the COVID-19 pandemic. *Sustain. Cities Soc.* 64(2021), 102582 (2021).
- [25] Li, Q., Guan, X., Wu, P., Wang, X., Zhou, L., Tong, Y., et al.: Early Transmission dynamics in Wuhan, China, of novel coronavirus–infected pneumonia. *N. Engl. J. Med.* (2020). <https://doi.org/10.1056/NEJMOa2001316>
- [26] Huang, C., Wang, Y., Li, X., Ren, L., Zhao, J., Hu, Y., et al.: Clinical features of patients infected with 2019 novel coronavirus in Wuhan, China. *Lancet* 395, 497–506 (2020)
- [27] Corman, V.M., Landt, O., Kaiser, M., Molenkamp, R., Meijer, A., Chu, D.K., et al.: Detection of 2019 novel coronavirus (2019- nCoV) by real-time RT-PCR. *Eurosurveillance* 25(3), 2000045 (2020).

- [28] Maad M. Mijwil, Implementation of Machine Learning Techniques for the Classification of Lung X-Ray Images Used to Detect COVID-19 in Humans. in: Iraqi Journal of Science, 2021, Vol. 62, No. 6, pp: 2099-2109, 16/3/2021.
- [29] Tulin Ozturk, M. Talo, E. A. Yildirim, U. B. Baloglu, O.Yildirim, U. R. Acharya, Automated detection of COVID-19 cases using deep neural networks with X-ray images, in: Computers in Biology and Medicine, Available online 28 April 2020.
- [30] Shervin Minaee, R. Kafieh, M. Sonka, Sh. Yazdani, Gh. Jamalipour Soufi, Deep-COVID: Predicting COVID-19 from chest X-ray images using deep Transfer learning, in: Medical Image Analysis, Volume 65, October 2020, 101794, Available online 21 July 2020.
- [31] Harsh Panwar, P.K. Gupta, M. Kh. Siddiqui, R. M. Menendez, V. Singh, Application of deep learning for fast detection of COVID-19 in X-Rays using nCOVnet, in: Modeling and forecasting of epidemic spreading: the case of Covid-19 and beyond, Volume 138, September 2020, 109944.
- [32] Soumya Ranjan Nayak, D. R. Nayak, U.Sinha, V. Arora, R. B. Pachori, Application of deep learning techniques for detection of COVID-19 cases using chest X-ray images: A comprehensive study, in: Biomedical Signal Processing and Control, Volume 64, February 2021, 102365.
- [33] Loveleen Gaur, U. Bhatia, N. Z. Jhanjhi, Gh. Muhammad, M. Masud, Medical image-based detection of COVID-19 using Deep Convolution Neural Networks, in: Role of Deep Learning Models & Analytics in Industrial Multimedia Environment, 28 April 2021.
- [34] M.K. Pandit, S.A. Bandy, R. Naaz, M.A. Chishti, Automatic detection of COVID-19 from chest radiographs using deep learning, Radiography, Volume 27, Issue 2, May 2021, Pages 483-489.
- [35] Andre G.C. Pacheco, Renato A. Krohling, The impact of patient clinical information on automated skin cancer detection, Comput. Biol. Med. 116 (2020), <https://doi.org/10.1016/j.combiomed.2019.103545>, 103545ISSN 0010- 4825.
- [35] J. Abdul Jaleel, Sibi Salim, Aswin.R.B, Artificial Neural Network Based Detection of Skin Cancer, in: International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering, Vol. 1, Issue 3, September 2012.
- [36] Maad M. Mijwil, Skin cancer disease images classification using deep learning solutions, in: Multimedia Tools and Applications, 2021 - Springer.
- [37] Dr. J. Abdul Jaleel, Sibi Salim, Aswin.R.B, Artificial Neural Network Based Detection of Skin Cancer, in: International Journal of Advanced Research in Electrical, Electronics and Instrumentation Engineering Vol. 1, Issue 3, September, 2012.
- [38] Uzma Bano Ansari, Tanuja Sarode, Skin Cancer Detection Using Image Processing, in: International Research Journal of Engineering and Technology (IRJET), Volume: 04 Issue: 04 | Apr -2017.
- [39] A. Murugan, S.Anu H. Nair, K. P. Sanal Kumar, Detection of Skin Cancer Using SVM, Random Forest and kNN Classifiers, in: IMAGE & SIGNAL PROCESSING, Journal of Medical Systems (2019) 43:269.
- [40] Ni Zhang, Yi-Xin Cai, Yong-Yong Wang, Yi-Tao Tian, Xiao-Li Wang, Benjamin Badami, Skin Cancer Diagnosis Based on Optimized Convolutional Neural Network, in: Artificial Intelligence In Medicine, 5 November 2019.
- [41] Md. Muzahidul Islam Rahi, F. Tanvir Khan, A. K. M. Amanat Ullah, et. al., DETECTION OF SKIN CANCER USING DEEP NEURAL NETWORKS, in: SUNY AT STONY BROOK, C from IEEE Xplore, August 09,2020.
- [42] Ibrahim AlShourbaji, Ghassan Samara, Shadab alam, et. al., Early detection of skin cancer using deep learning approach, xllkogretim Online - Elementary Education Online,2021; Vol 20 (Issue 5): pp.3880-3884.