



تطوير نظام إلكتروني لتحليل وتشخيص صور الأشعة السينية لتصنيف كسور العظام باستخدام خوارزميات التعلم الآلي

بدور محمد الرشاح، فاطمة سليمان هويدي*، و مودة عمر الظفير

قسم علوم الحاسوب، كلية تقنية المعلومات، الجامعة الأسمرية الإسلامية، زليتن، ليبيا.

*البريد الإلكتروني: f.howedi@asmarya.edu.ly

Developing an Electronic System for Analyzing and Diagnosing X-Ray Images to Classify Bone Fractures Using Machine Learning Algorithms

Budor Mohammed Alrashah, Fatma Sulyman Howedi*, and Mawada Omar Aldhafeer

Department of Computer Science, Faculty of Information Technology, Alasmarya Islamic University, Zliten, Libya.

المخلص

يعد الذكاء الاصطناعي من التقنيات الواعدة في مجال التصوير الطبي، لما له من دور فعال في تحسين دقة وكفاءة التشخيص وتقليل الأخطاء البشرية. وغالباً ما تُستخدم صور الأشعة السينية على نطاق واسع في تشخيص كسور العظام الناتجة عن الحوادث، والشيخوخة، وهشاشة العظام، إلا أن التقييم اليدوي لهذه الصور قد يكون مرهقاً ومعرضاً للأخطاء، خاصة في حالات الكسور الدقيقة التي يصعب اكتشافها بسبب قلة الخبرة أو ضعف وضوح الصورة، مما قد يؤدي إلى تشخيص غير دقيق. لذلك يهدف هذا البحث إلى تطوير نظام ذكي قائم على تقنيات التعلم الآلي لتحليل وتشخيص صور الأشعة السينية لكسور العظام، بهدف تحسين دقة التشخيص وتسريع عملية الكشف، مع تقليل الأخطاء الطبية المحتملة. حيث تم اعتماد المنهج الوصفي التحليلي في تحليل وتصميم النظام. كما تم توظيف مجموعة من الأدوات والتقنيات، من أبرزها لغة البرمجة Python، ومنصتي Google Colab و Jupyter، إضافة إلى برنامج Crystal Reports. يعتمد النظام على تدريب خوارزميات التصنيف SVM و KNN باستخدام مجموعة بيانات من صور الأشعة السينية التي تشمل عظاماً مكسورة وغير مكسورة، وذلك بعد تطبيق عمليات المعالجة المسبقة للصور واستخراج الميزات المناسبة. أظهرت نتائج المقارنة تفوق نموذج SVM، حيث حقق دقة اختبار بلغت 83.36% مقابل 82.86% لنموذج KNN، كما سجل نموذج SVM دقة وصلت إلى 96% عند اختباره مع مجموعة بيانات متوازنة مقابل 52% لنموذج KNN. وبالتالي فإن نموذج SVM أكثر ملائمة وموثوقية للاعتماد عليه في تشخيص كسور العظام لصور الأشعة السينية. كما تؤكد النتائج فعالية النظام المقترح في تحسين التصنيف، وتبرز كفاءة الذكاء الاصطناعي في دعم تشخيص كسور العظام بما يحسن جودة الرعاية الصحية ويقلل العبء عن اختصاصي الأشعة.

الكلمات الدالة: نظام إلكتروني، الأشعة السينية، كسور العظام، التعلم الآلي، الذكاء الاصطناعي.

Abstract

Artificial Intelligence (AI) has become a powerful tool in medical imaging, improving diagnostic accuracy and reducing human errors. X-ray images are widely used to diagnose bone fractures caused by accidents, aging, and osteoporosis; however, manual interpretation is often time-consuming and prone to inaccuracies, especially in subtle fracture cases. This study proposes an intelligent machine learning–based system for automated bone fracture detection from X-ray images. A descriptive-analytical methodology was adopted, and the system was designed using the Waterfall Model. The system uses Python, Jupyter, and Google Colab. Two classification algorithms, Support Vector Machine (SVM) and K-Nearest Neighbors (KNN), were trained using a dataset containing fractured and non-fractured bone images after applying image preprocessing and feature extraction techniques. Experimental results showed that the SVM model outperformed the KNN model, achieving an accuracy of 83.36% compared to 82.86%. Additionally, the SVM model reached an accuracy of 96% when evaluated on a balanced test dataset, compared to 52% for the KNN model. These results demonstrate the effectiveness of the proposed system in improving classification and highlight the efficiency of artificial intelligence in supporting bone fracture diagnosis, thus improving the quality of healthcare and reducing the burden on radiologists.

Keywords: *Electronic System, X-ray, Bone fractures, Machine learning, Artificial intelligence (AI).*

1. المقدمة

تُعتبر كسور العظام من الإصابات الشائعة التي يتعرض لها الإنسان، وهي تمزق أو كسر في هيكل العظم، يمكن أن يكون على شكل تشققات صغيرة أو كسور كاملة. تحدث الكسور لأسباب متعددة، منها الشيخوخة، الحوادث، السقوط، وأمراض العظام مثل هشاشة العظام (Bigham-Sadegh & Oryan, 2015). تُعد الأشعة السينية X-ray الطريقة الأكثر شيوعًا لتشخيص الكسور، حيث يعتمد المتخصصون إلى حد بعيد على هذه الصور لتحديد ما إذا كان هناك كس وتحديد الموقع الدقيق له. ومع ذلك، يتطلب التقييم اليدوي للكشف عن الكسور وقتًا وجهدًا كبيرًا من أخصائي الأشعة. في بعض الأحيان، تكون الشقوق في العظام صغيرة جدًا، بحيث لا يتمكن المتخصصون من اكتشافها بسهولة. وعلى الرغم من أن الكسر يمكن التعرف عليه بسهولة في بعض الحالات من صورة الأشعة السينية، إلا أن العملية ليست دائمًا بهذه السهولة. هناك حالات قد يكون فيها الخبير لديه شكوك حول وجود الكسر. علاوة على ذلك، من المعروف أن الإجهاد والمهام المتكررة قد تؤدي إلى حدوث أخطاء بشرية بسبب التعب. ولهذا السبب، فإن معظم أخصائيو الأشعة، بما في ذلك كبار الخبراء في هذا المجال، يفقدون الدقة بعد مرور فترة معينة (Mehta et al., 2023). لذلك يلعب الذكاء الاصطناعي دورًا مهمًا في تحسين اكتشاف الكسور من خلال صور الأشعة السينية. حيث يمكن الاعتماد على

خوارزميات التعلم الآلي (Machine Learning (ML للتعرف على الأنماط واستخلاص المعلومات المفيدة من البيانات. كما يعتبر التنقيب في البيانات عنصراً أساسياً في تعزيز فعالية هذه الأنظمة عن طريق تحليل كميات ضخمة من بيانات الأشعة السينية. من خلال تقديم بيانات تدريب شاملة، يمكن أن يعزز التنقيب في البيانات دقة وكفاءة الأنظمة، مما يساهم في تحسين جودة الرعاية الصحية وتسريع عملية التشخيص (Wang et al., 2017). ومن خلال الاستفادة من تقنيات الذكاء الاصطناعي، يمكن لمتخصصي الأشعة الاستعانة بالأدوات التي تعتمد على الكمبيوتر، والتي تُساعد على تفسير صور الأشعة السينية، مما يؤدي إلى اكتشاف الكسور بسرعة ودقة أكبر. علاوة على ذلك، تتمتع أنظمة الذكاء الاصطناعي بالقدرة على توفير تقييمات موحدة ومتسقة، مما يقلل من التباين بين المراقبين، ويحسن النتائج (Thorat et al., 2024). لهذا يهدف هذا البحث لأنشاء نظاماً لتصنيف كسور العظام باستخدام خوارزميات التعلم الآلي، لمساعدة الأطباء في تحليل صور الأشعة السينية واكتشاف الكسور بدقة وسرعة. وذلك من خلال تدريب خوارزميتين هما خوارزمية آلة المتجهات الداعمة Support Vector Machine (SVM) وخوارزمية الجار الأقرب K-Nearest Neighbors (K-NN). ذلك بتزويد كلاً منهما بمعلومات حول الأنماط والسمات المميزة للكسور، مما يسمح لها بتعلم كيفية التعرف عليها وتمييزها في صور الأشعة الجديدة.

يتكون النظام المقترح من جزئين رئيسيين يتمثل الجزء الأول في بناء نماذج تعلم آلي باستخدام خوارزميتي (SVM و K-NN) بعد تدريبها على مجموعة من صور الأشعة السينية للعظام المكسورة بحيث تتعلم مميزات وصفات الكسور، وهذا الجزء هو الجزء الأساسي الذي يعتمد عليه البحث في التشخيص الآلي للصور الجديدة التي لم يتدرب عليها مسبقاً ومن تم معرفتها آلياً وتصنيفها الى مكسورة أو غير مكسورة. أما الجزء الثاني للبحث فيتمثل في بناء نظام إلكتروني بواجهات سهلة الاستخدام يتم من خلالها تحميل صور الأشعة للمريض وتشخيصها آلياً باستخدام النماذج المدربة التي تم بناؤها، وذلك بعد مقارنة نتائج النموذجين لاختيار الأكثر دقة.

تكمن أهمية هذا البحث في التغلب على مشاكل التشخيص اليدوي للكسور من خلال تحليل الصور لزيادة دقة تشخيص الكسور باستخدام التعلم الآلي وتقليل الوقت المطلوب لتشخيص الكسور، وكذلك تقليل الأخطاء الطبية التي قد تحدث أثناء تشخيص الكسور، مما يجعله ذا أهمية كبيرة لمتخصصي الأشعة السينية، ليسهم في تصنيف كسور العظام بدقة عالية، وتسريع عملية تشخيص الكسور.

2. الدراسات السابقة

تم في هذه الفقرة عرض ومناقشة عدد من الأبحاث والدراسات السابقة التي تحتوي على معلومات ذات صلة بعنوان وفكرة البحث، مما يوفر له قاعدة من المعلومات الواسعة حول الموضوع. تُعزز الدراسات المشابهة فهم كيفية تطبيق الخطوات بشكل فعال، وفيما يلي أهم الدراسات ذات الصلة:

قام الباحث Goel وآخرون (2025) بدراسة استخدم خلالها نموذج شبكة عصبية التلافيفية (CNN) مُصمماً للتعرف الآلي على كسور اليد من صور الأشعة السينية، باستخدام مجموعة بيانات تضم 10000 صورة أشعة سينية لليد. حقق النموذج دقة بلغت 96.68%. وفي دراسة قام بها الباحثان Wani و Arora (2023) هدفت إلى تطوير نموذج لتشخيص هشاشة العظام باستخدام صور أشعة السينية للركبة، بالاعتماد على نقل التعلم والشبكات العصبية التلافيفية (CNN). استخدم الباحثان تقنيات نقل التعلم من نماذج مدربة مسبقاً منها نموذج Alexnet و Res-Net، بالإضافة إلى معالجة الصور من خلال تطبيع الصور وتحسين التباين حيث حققت دراسة دقة بلغت 91.1 %، استخدمت عدد 381 صورة أشعة سينية للركبة (Wani & Arora, 2023). أيضاً في سنة 2023 قام الباحث Noreen وآخرون بدراسة هدفت إلى تحليل وتصنيف كسور العظام، وقد طوروا نموذجاً عميقاً يعتمد على هيكلية AlexNet حيث حقق النموذج دقة عند 95%، باستخدام مجموعة بيانات MURA التي تضم أكثر من 40,000 صورة (Noreen et al., 2023). اختلفت الدراستان عن موضوع البحث الحالي في الجزء المحدد للتشخيص، وعدد الصور، ونوع النماذج المستخدمة، حيث تم في هذا البحث بناء نماذج من خوارزميات SVM و KNN، مع الاعتماد على صور الأشعة السينية للعظام الطويلة. وفي المقابل تشابه هذا البحث مع دراسة الباحث Mehta وآخرون (2023) في نظام الكشف عن كسور العظام مع استخدام تقنية التعلم الآلي SVM، KNN، ولكن اختلف هذا البحث مع الدراسة Mehta وآخرون باستخدامهم تقنيات التعلم العميق (CNN، Faster R-CNN، DNN). والانحدار اللوجستي. حيث حققت دراستهم تحسن في الكشف عن الكسور باستخدام 83,863 صورة الأشعة السينية (Mehta et al., 2023).

وفي عام (2022) أجرى الباحث Üreten وآخرون دراسة هدفت إلى تطوير نظام للكشف التلقائي عن كسور اليد من صور الأشعة السينية، بالاعتماد على التعلم العميق. حيث تم استخدام CNN التلافيفية مع نموذج VGG-16 لتحليل الصور عبر تحسين الحواف وتطبيع الصور، باستخدام مجموعة بيانات مكونة من 802 صورة أشعة سينية لليد. حققت الدراسة دقة عند 93.3 % كأعلى نسبة باستخدام نموذج VGG-16 (Üreten et al., 2022). واختلفت الدراسة عن البحث الحالي في

نوع النماذج المستخدمة، والجزء المحدد في التشخيص. وفي العام نفسه (2022) قام الباحث Wang وآخرون بتطوير نموذج لتصنيف كسور الفك السفلي مع معالجة الصور عبر تقسيم الصور وتحسين التفاصيل الدقيقة، اختلفت هذه الدراسة عن موضوع البحث في المصنفات المستخدمة، ونوع الصور، وعددها. حيث تم استخدام خوارزمية CNN التلافيفية مع نموذج KDenseNet وتم استخدام 686 صورة من التصوير المقطعي المحوسب (CT) لتدريب النموذج (Wang et al., 2022)، وحقت الدراسة دقة تجاوزت 90% مع نموذج U-Net. كذلك تناولت دراسة الباحثان Vironicka و Sathiasela (2022) لتطوير إطار عمل لتصنيف كسور العظام الطويلة حيث استخدمت الدراسة المعالجة المسبقة بتجزئة الصور، وكشف الحواف، لاستخراج الميزات، بالإضافة إلى نموذج Faster-RCNN المعدل والذي حقق معدل دقة عند 94% (Vironicka & Sathiasela, 2022).

وفي دراسة أخرى أجراها الباحث Bagaria وآخرون (2021) هدفت إلى تطوير نموذج للكشف عن كسور العظام باستخدام صور الأشعة السينية وتقنيات التعلم العميق. تم استخدام نموذج الشبكة العصبية التلافيفية (CNN) في تصنيف الكسور حقق النموذج دقة تقارب 90%، مع عمليات المعالجة المسبقة مثل التطبيع وتحسين التفاصيل الدقيقة، وذلك باستخدام 200 صورة (Bagaria et al., 2021).

وبالمقابل يعتمد هذا البحث على أنظمة التعلم الآلي وهي أنظمة تعتمد على خوارزميات ونماذج رياضية لتحليل كميات كبيرة من البيانات، واستخلاص أنماط ومعرفة منها، ومن ثم استخدام هذه المعرفة لاتخاذ قرارات أو تقديم توقعات دقيقة (عوكل، 2021). لا توجد خوارزمية واحدة مناسبة لكل مشكلة في التعلم الآلي، لذا يجب تجربة عدة خوارزميات لتقييم الأداء واختيار الأنسب. لذلك تم استخدام خوارزمتين في هذا البحث وهما SVM و K-NN. تعتبر خوارزمية SVM أو آلة المتجهات الداعمة من خوارزميات التعلم الخاضع للإشراف، تُستخدم لحل مشكلات التصنيف والانحدار. تركز على تقسيم مجموعات البيانات إلى فئات مختلفة وتستخدم في تصنيف الصور واكتشاف الأدوية. أما خوارزمية أقرب جار أو KNN تُستخدم لحل مشكلات التصنيف والانحدار، وتعتمد على افتراض أن النقاط المتقاربة (مثل الجيران) تربط بناءً على الحاجة إلى إنشاء معايير جديدة.

يتميز نموذج خوارزمية SVM بقدرته على تصنيف البيانات ذات الأبعاد العالية مثل الصور، بفضل قدرته على إيجاد الحدود الفاصلة المثلى بين الفئات في الفضاء ذي الأبعاد العالية، ويعمل بشكل جيد حتى مع مجموعة بيانات صغيرة (ذويب، 2020). بينما نموذج K-NN لا يتطلب تدريباً معقداً بدلاً من ذلك، تستخدم مجموعة التدريب مباشرةً في مرحلة التصنيف، ويتمتع نموذج KNN بالقدرة على

التكيف مع أنواع مختلفة من البيانات ويعمل بشكل جيد مع البيانات التي تحتوي على حدود غير خطية بين الفئات، ولكنه قد يكون بطيئاً مع مجموعة البيانات كبيرة (ذويب، 2020).

3. المنهجية وطرق العمل


يعرض هذا الجزء المنهجية التي تم الاعتماد عليها في تحليل وتصميم نظام تصنيف الكسور، وكذلك توضيح أهم التقنيات ولغات البرمجة المستخدمة في بناء النظام، وتوضيح طريقة عمل ومراحل بناء نماذج التعلم الآلي التي سيعتمد عليها النظام في تحليل وكشف الصور فيما إذا كانت مكسورة أو غير مكسورة.

1.3. نمذجة وتحليل النظام


تم تحليل النظام وتوضيح العمليات والمتطلبات بواسطة لغة النمذجة الموحدة (UML)، والتي تضم عدة مخططات مختلفة تساعد على تقديم نظرة شاملة على النظام من زوايا وأبعاد مختلفة. ومن أهم المخططات التي تم استخدامها مخطط حالات الاستخدام (Use case Diagram)، هو المخطط المسؤول عن توضيح الأدوار والمواقف المتعلقة بالنظام (Murti, 2022; Howedi et al., 2023). الشكل (1) يوضح مخطط حالة الاستخدام لنظام تصنيف الكسور. أما الشكل (2) يوضح المخطط التسلسلي لعملية إضافة وتحليل صور الأشعة السينية.

2.3. الأدوات والتقنيات المستخدمة في إنشاء النظام

لإنجاز هذا البحث، تم الاعتماد على مجموعة من الأدوات والتقنيات البرمجية التي تكاملت فيما بينها لبناء نظام إلكتروني لتحليل وتشخيص صور الأشعة السينية وتصنيف كسور العظام. حيث استُخدمت لغة البرمجة Python في الجانب التحليلي للنظام، إذ تم توظيفها في تنفيذ مراحل المعالجة المسبقة لصور الأشعة، واستخراج الميزات، وتدريب نماذج التصنيف المعتمدة على خوارزميات آلة المتجهات الداعمة (SVM) وخوارزمية أقرب الجيران (KNN)، وذلك لما تتمتع به هذه اللغة من دعم واسع لمكتبات معالجة الصور والذكاء الاصطناعي (طعيمة، 2020). مما يجعلها مناسبة للأبحاث العلمية وبناء النماذج الذكية.



شكل 1. مخطط حالة الاستخدام لنظام تصنيف الكسور



شكل 2. المخطط التسلسل لعملية إضافة وتحليل صور الأشعة السينية

وفي المقابل، تم استخدام لغة البرمجة C# لتطوير الواجهة الأمامية للنظام، حيث تم من خلالها تصميم تطبيق إلكتروني يعمل على سطح المكتب يتيح للمستخدم إدخال صور الأشعة وعرض نتائج التشخيص، بالاعتماد على إطار العمل .NET. لما يوفره من بيئة مستقرة لتطوير تطبيقات سطح المكتب وربطها بقواعد البيانات. وقد تم تنفيذ وتطوير هذا الجزء باستخدام بيئة Visual Studio 2022 لما توفره من أدوات متقدمة لإدارة الكود وتصحيح الأخطاء ودعم تطوير تطبيقات C# بكفاءة عالية (قمو وآخرون، 2023).

كما تم الاعتماد على نظام إدارة قواعد البيانات SQL Server لتخزين وتنظيم بيانات النظام، بما في ذلك بيانات الصور ونتائج التصنيف، نظراً لما يتميز به من موثوقية وقابلية للتوسع ودعم عمليات النسخ الاحتياطي. بالإضافة إلى ذلك، تم استخدام برنامج Crystal Reports لإنشاء تقارير تفاعلية لعرض نتائج التشخيص وتحليل البيانات المستخرجة من قاعدة البيانات بطريقة منظمة تدعم عملية اتخاذ القرار.


أما فيما يخص تدريب النماذج وتنفيذ خوارزميات التعلم الآلي، فقد تم استخدام منصة Google Colab لتشغيل أكواد Python الخاصة بالنظام ضمن بيئة سحابية تدعم مكتبات الذكاء الاصطناعي، مما سهّل عملية التدريب دون الحاجة إلى تجهيزات محلية متقدمة. كما تم الاستعانة بمنصة Jupyter Lab لتحليل البيانات واختبار نماذج التصنيف وتطبيق مراحل المعالجة المسبقة، إلى جانب استخدام نموذج YOLOv7 لتحديد مواقع الكسور في صور الأشعة السينية وإحاطتها بإطارات، مما ساهم في تعزيز دقة التشخيص ودعم عملية التصنيف.

3.3. مراحل بناء نماذج التعلم الآلي لنظام تصنيف الكسور

تم في هذه الخطوة بناء نموذجي SVM و KNN لاستخدامهما في نظام تصنيف كسور العظام واستخراجها من صور الأشعة السينية عبر معالجة الصور وتحليلها بخوارزميات التعلم الآلي. عملية بناء نماذج التعلم الآلي في هذا البحث مرت بعدة مراحل وهي كما بالشكل (3)، والذي يوضح أن آلية بناء نماذج التعلم الآلي تعتمد على مجموعة من الخطوات المتسلسلة لبناء نموذج قادر على التنبؤ واتخاذ القرارات بناءً على البيانات المدخلة. فيما يلي الخطوات أو المراحل الأساسية لعمل نماذج التعلم الآلي: المرحلة الأولى: الحصول على بيانات التدريب، تم استخدام صور من مجموعة بيانات Frac Atlatl، وهي مجموعة بيانات لكسور العظام العظمية الهيكلية، تحتوي على عدد (4000) صورة أشعة. المرحلة الثانية: إجراء المعالجة الأولية للصور، ومن عمليات المعالجة التي تم تطبيقها على الصور الآتي:

- تساوي توزيع الأضواء (Histogram Equalization): تم استخدام هذه العملية لضبط تباين الصور، مما يعزز وضوحها ويحسن كفاءة التعرف على الأشياء.
- فلتر الوسيط (Median filter): يعمل هذا الفلتر على تقليل الضوضاء، من خلال استبدال كل قيمة بالقيمة الوسطى للقيم المجاورة. يحافظ هذا الفلتر على الحواف والتفاصيل الهامة، ويستخدم لتحسين جودة الصور، وتعزيز الدقة في التحليل (Cloudinary, 2024).
- تحسين التباين (Contrast Enhancement): يستخدم لزيادة الفارق بين الأجزاء الفاتحة والداكنة في الصور، مما يحسن وضوح التفاصيل.
- تطبيع البيانات (Data Normalization): ثم استخدام تقنيتين لتطبيع البيانات، وهي:
1) التطبيع بالحد الأدنى والحد الأقصى (Min-Max Scaling): تستخدم لضبط قيم البيكسل لتكون ضمن نطاق معين (مثل 0 إلى 1 أو -1 إلى 1).

- (2) تطبيع الدرجة المعيارية (Z-score normalization): هو عملية تعديل القيم لتصبح بمتوسط 0 وانحراف معياري 1، مما يحسن استقرار النموذج ويسرع تدريبه، وذلك من خلال طرح المتوسط من كل قيمة وقسمتها على الانحراف المعياري.
- تحجيم الصور (Resize Image): تعديل أبعاد الصور إلى حجم محدد حيث تم تحديد الحجم عند (224,224).



شكل 3. مراحل بناء نماذج التعلم الآلي الخاصة بنظام تصنيف صور كسور العظام

يوضح الشكلان (4 و 5) صور الأشعة السينية للعظام المكسورة والعظام السليمة وذلك قبل عمليات المعالجة الأولية. أما الشكلان (6 و 7) فهي توضح صور الأشعة السينية بعد تطبيق عمليات المعالجة الأولية.



شكل 5. عظم سليم بدون معالجة أولية



شكل 4. عظم مكسور بدون معالجة أولية



شكل 7. عظم سليم بعد المعالجة الأولية




شكل 6. عظم مكسور بعد المعالجة الأولية


المرحلة الثالثة: استخراج الميزات، تعتبر هذه المرحلة شكلاً من أشكال التنقيب عن البيانات، حيث يتم تحديد الخصائص الأكثر صلة بالصورة لتسهيل عملية التصنيف (Wang et al., 2017). في هذا البحث، تم استخراج الميزات التالية:

- ميزة الحواف: تم استخراجها باستخدام خوارزمية Canny Edge Detector، التي تكشف عن الحدود بين المناطق المختلفة في الصورة (Towards AI, 2020).

- **ميزة الأشكال:** تم تحديدها باستخدام Hough Transform، الذي يكتشف الأشكال الهندسية مثل الخطوط والدوائر (Bhalla, 2024).
 - **ميزة الزوايا:** تم استخراجها باستخدام Harris Corner Detector، الذي يحدد النقاط الحادة أو الزوايا في الصورة. كما يتم إسناد التسميات المناسبة لكل صورة بناءً على هذه الميزات لتصنيف وتحليل الصور.
- يوضح الشكل (8) صور الأشعة السينية لعظم مكسور بعد استخراج الميزات ويبين الشكل (9) صورة أشعة سينية لعظم سليم بعد استخراج الميزات.



شكل 9. عظم سليم بعد استخراج ميزة الحافة



شكل 8. عظم مكسور بعد استخراج ميزة الحافة

المرحلة الرابعة: تدريب النموذج، تم تدريب خوارزميتي SVM و KNN على البيانات المستخلصة من مرحلة استخراج الميزات. حيث تم ضبط متغير (test_size) على القيمة (0.3)، مما يعني تقسيم البيانات إلى مجموعة تدريب بنسبة (70%) ومجموعة اختبار بنسبة (30%). كما تم ضبط المتغير (random_state) على القيمة (42)، وهو المسؤول عن تثبيت تكرار تقسيم البيانات لضمان استقرار نتائج التدريب، بالنسبة لنموذج SVM تم تحديد نوع النواة (linear). بينما تم ضبط معامل نموذج KNN لتحديد أقرب الجيران على القيمة (K=9)، الشكل (10) يوضح ضبط النماذج.

```
# تدريب نموذج SVM
svm_model = SVC(kernel='linear', probability=True)
svm_model.fit(x_train, y_train)

# تدريب نموذج KNN
knn_model = KNeighborsClassifier(n_neighbors=9)
knn_model.fit(x_train, y_train)
```

شكل 10. ضبط النماذج

المرحلة الخامسة: تقييم النتائج، بعد الانتهاء من مرحلة تدريب نموذجي SVM و KNN تم تقييم أداء النموذجين للتحقق من قدرتهما على التنبؤ الصحيح بالحالات غير المرئية أثناء التدريب وذلك بالاعتماد على مجموعة بيانات الاختبار لم تُستخدم في عملية التدريب، حيث تم تقييم أداء النماذج من خلال عدة المقاييس وهي الدقة، ومنحنى ROC، وتقرير التصنيف. وذلك لقياس كفاءة النماذج وقدرتها على التعميم.

- الدقة (Accuracy): تم حساب الدقة لقياس النسبة الإجمالية للتصنيفات الصحيحة إلى إجمالي عدد العينات، وهي مؤشر عام على كفاءة النموذج في أداء مهمة التصنيف.
- منحنى ROC: كما تم استخدام منحنى ROC لتقييم قدرة النموذج على التمييز بين الفئات المختلفة عند قيم عتبة متعددة، حيث يُعد هذا المقياس مناسباً لمشكلات التصنيف الثنائي.
- تقرير التصنيف (Classification Report): تم استخدام تقرير التصنيف الذي يتضمن مقاييس الدقة والاسترجاع ودرجة F1 لكل فئة، مما يوفر تقييماً أكثر تفصيلاً لأداء النموذج.

أظهرت نتائج التقييم وجود اختلاف في أداء خوارزميتي SVM و KNN، حيث حقق كل نموذج مستويات متفاوتة من الدقة ومعدلات الخطأ، مما يبرز أهمية اختيار الخوارزمية المناسبة لطبيعة البيانات المستخدمة.

4. النتائج والمناقشة

في هذا الجزء تم تحليل ومناقشة نتائج اختبار نماذج التعلم الآلي SVM و K-NN والتي تم تدريبها وبناءها لغرض تحليل صور الأشعة السينية وتصنيفها لعظام مكسورة أو غير مكسورة. كما تم عرض نتائج تنفيذ واجهات نظام تصنيف الكسور المعتمد على نماذج التعلم الآلي (SVM و K-NN) وذلك في الملحق. تعرض هذه الفقرة مناقشة ومقارنة النتائج التي تم الحصول عليها بعد تدريب واختبار نموذجي SVM و KNN على صور الأشعة للعظام باستخراج ثلاثة خصائص (مميزات) من الصور

خاصية الحواف، الاشكال، والزوايا لاختيار الأفضل في التعامل مع صور الأشعة السينية وتحليلها. وعند تنفيذ الكود الخاص باستخراج خاصية الزوايا من الصور، تم تحقيق دقة بلغت 82.20% لنموذج SVM ودقة بلغت 81.21% لنموذج KNN، والشكل (11) يوضح اجمالي الدقة للنموذجين باستخراج ميزة الزوايا من مجموعة بيانات الاختبار.

أما الشكل (12) يبين اجمالي الدقة للنموذجين باستخراج خاصية الحواف من صور مجموعة بيانات الاختبار، حيث حقق SVM دقة بلغت 81.87% بينما وصل نموذج K-NN عند 81.79%. وبعد تنفيذ الكود الخاص باستخراج خاصية أو ميزة الاشكال من الصور المعالجة وصلت دقة نموذج SVM عند 81.29% وعند 80.96% لنموذج K-NN، وذلك كما بالشكل (13).

```
# دقة النموذجين عند استخراج ميزة الزوايا
svm_accuracy = svm_model.score(x_test, y_test)
knn_accuracy = knn_model.score(x_test, y_test)
print(f"SVM Accuracy: {svm_accuracy * 100:.2f}%")
print(f"KNN Accuracy: {knn_accuracy * 100:.2f}%")

SVM Accuracy: 82.20%
KNN Accuracy: 81.21%
```

شكل 11. اجمالي الدقة للنموذجين باستخراج ميزة الزوايا من مجموعة بيانات الاختبار

```
# دقة النموذجين عند استخراج ميزة الحواف
svm_accuracy = svm_model.score(x_test, y_test)
knn_accuracy = knn_model.score(x_test, y_test)
print(f"SVM Accuracy: {svm_accuracy * 100:.2f}%")
print(f"KNN Accuracy: {knn_accuracy * 100:.2f}%")

SVM Accuracy: 81.87%
KNN Accuracy: 81.79%
```

شكل 12. اجمالي الدقة للنموذجين باستخراج ميزة الحواف من مجموعة بيانات الاختبار

```
# دقة النموذجين عند استخراج ميزة الاشكال
svm_accuracy = svm_model.score(x_test, y_test)
knn_accuracy = knn_model.score(x_test, y_test)
print(f"SVM Accuracy: {svm_accuracy * 100:.2f}%")
print(f"KNN Accuracy: {knn_accuracy * 100:.2f}%")

SVM Accuracy: 81.29%
KNN Accuracy: 80.96%
```

شكل 13. اجمالي الدقة للنموذجين باستخراج ميزة الأشكال من مجموعة بيانات الاختبار

بمقارنة النتائج المتحصل عليها من النموذجين عند استخدام الميزات منفردة، كان أفضل أداء لنموذج SVM بدقة بلغت 82.20% باستخدام ميزة الزوايا. بالمقابل، حققت هذه الميزة دقة أقل بلغت

81.21% مع نموذج KNN. وهذا يشير إلى أن نموذج KNN كان أقل فعالية في تصنيف الصور بناءً على ميزة الزوايا مقارنة بنموذج SVM. وبالنظر إلى نتائج نموذج KNN نجد أن أفضل أداء للنموذج كان عند استخدام خاصية الحواف، حيث بلغت دقته 81.79%. حيث كان أكثر فاعلية نسبياً في هذه الحالة. في حين عند دمج الميزات الثلاثة (الحواف، الأشكال، الزوايا)، لوحظ أن دقة النموذجين قد ارتفعت عند 83.36% لنموذج SVM و82.86% لنموذج KNN. وبالتالي أظهرت النتائج أن نموذج SVM حقق أداءً أفضل من نموذج KNN في تقرر تصنيف الصور وذلك كما هو موضح بالشكل (14). كذلك يوضح الشكل (15) ملخص نتائج التصنيف للنموذجين باستخدام (Precision، Recall، F-Score) عند دمج جميع الميزات.

```
# دقة النموذجين عند دمج جميع الميزات (الأشكال و الحواف و الزوايا)
svm_accuracy = svm_model.score(x_test, y_test)
knn_accuracy = knn_model.score(x_test, y_test)
print(f"SVM Accuracy: {svm_accuracy * 100:.2f}%")
print(f"KNN Accuracy: {knn_accuracy * 100:.2f}%")

SVM Accuracy: 83.36%
KNN Accuracy: 82.86%
```

شكل 14. إجمالي الدقة للنموذجين بعد دمج جميع الميزات واستخراجها من مجموعة بيانات الاختبار

```
# تقرير التصنيف عند دمج جميع الميزات (الأشكال و الحواف و الزوايا)
print("SVM Classification Report:")
print(classification_report(y_test, svm_pred))
print("KNN Classification Report:")
print(classification_report(y_test, knn_pred))
```

SVM Classification Report:				
	precision	recall	f1-score	support
0	0.42	0.17	0.24	201
1	0.85	0.95	0.90	1007
accuracy			0.82	1208
macro avg	0.64	0.56	0.57	1208
weighted avg	0.78	0.82	0.79	1208

KNN Classification Report:				
	precision	recall	f1-score	support
0	0.33	0.00	0.01	201
1	0.83	1.00	0.91	1007
accuracy			0.83	1208
macro avg	0.58	0.50	0.46	1208
weighted avg	0.75	0.83	0.76	1208

شكل 15. ملخص نتائج التصنيف للنموذجين بعد دمج جميع الميزات مع مجموعة بيانات الاختبار

من الشكل (15) يتضح عدم وجود توازن في البيانات حيث كان عدد صور العظام المكسورة (الفئة 0) 201، بينما صور العظام غير المكسورة (الفئة 1) بلغ عددها 1007. نتيجة لذلك حقق نموذج

SVM أداءً مرتفعاً في تصنيف الفئة الأكبر عدداً غير مكسورة (الفئة 1) لكل من Precision %85 و %95 Recall و F1-score 0.90 %، وأظهر قدرة عالية على استرجاع العينات الصحيحة، مما يشير إلى كفاءته في التعرف على الأنماط السائدة في البيانات. في المقابل، انخفض أداء النموذج في تصنيف الفئة الأقل تمثيلاً (الفئة 0) لكل من Precision %42 و Recall %17 و F1-score 0.24 %، ويُعزى ذلك إلى عدم توازن مجموعة البيانات، حيث يميل النموذج إلى تفضيل الفئة ذات التمثيل الأعلى. وبالمقارنة، حقق نموذج KNN نتائج مرضية في استرجاع فئة غير مكسورة (فئة 1) حيث بلغت F1-score 0.92 %، مع فشل ملحوظ في استرجاع فئة (0) مكسورة حيث كانت F1-score 0.01 %، مما يشير إلى محدودية في هذا السياق. وهذا تأثير طبيعي لعدم توازن البيانات. وبذلك يعكس هذا السلوك حساسية خوارزمية KNN العالية لتوزيع البيانات، خاصة في حالة عدم التوازن، مما يؤدي إلى تجاهل الفئات الأقل تمثيلاً. هذا تفسير متوقع جداً في KNN عند عدم موازنة البيانات.


عند مقارنة أداء النموذجين، يتضح أن نموذج SVM أكثر توازناً من حيث قدرته على تصنيف كلا الفئتين مقارنةً بنموذج KNN، الذي أظهر انحيازاً واضحاً نحو الفئة الأكبر عدداً. وعلى الرغم من تحقيق KNN لدقة عامة مرتفعة، إلا أن ضعف أدائه في تصنيف الفئة الأقل تمثيلاً يقلل من فعاليته في التطبيقات التي تتطلب اكتشاف جميع الفئات بدقة. وللتغلب على مشكلة عدم توازن مجموعة البيانات تمت إعادة هذه التجارب مع بيانات متوازنة مكونة من 1985 صورة، عدد المكسورة (993) والغير مكسورة (992) لمجموعة البيانات الاختبار. يوضح الشكل (16) ملخص نتائج التصنيف للنموذجين مع مجموعة بيانات متوازنة.

# التقارير التفصيلية					
print("SVM Classification Report:")					
print(classification_report(y_test, svm_pred))					
print("KNN Classification Report:")					
print(classification_report(y_test, knn_pred))					
SVM Accuracy: 0.96					
KNN Accuracy: 0.52					
SVM Classification Report:					
	precision	recall	f1-score	support	
0	0.97	0.96	0.96	993	
1	0.96	0.97	0.96	992	
accuracy			0.96	1985	
macro avg	0.96	0.96	0.96	1985	
weighted avg	0.96	0.96	0.96	1985	
KNN Classification Report:					
	precision	recall	f1-score	support	
0	0.51	1.00	0.68	993	
1	0.96	0.05	0.09	992	
accuracy			0.52	1985	
macro avg	0.74	0.52	0.38	1985	
weighted avg	0.74	0.52	0.38	1985	


شكل 16. ملخص نتائج التصنيف للنموذجين لمجموعة بيانات متوازنة مع دمج جميع المزايا.

وفقاً للشكل (16)، تظهر نتائج اختبار النموذجين تفوقاً واضحاً لنموذج SVM مقارنةً بنموذج KNN، حيث حقق نموذج SVM دقة تصنيف بلغت 96% على مجموعة اختبار متوازنة ومكونة من 1985 صورة، وسجل قيمة مرتفعة لكل من Precision و Recall و F1-score بلغت 0.96 لكلا الفئتين المكسورة وغير المكسورة، مما يدل على كفاءة عالية في التمييز بين صور الكسور وغير الكسور. في المقابل، أظهر نموذج KNN أداءً ضعيفاً نسبياً، حيث بلغت دقته الكلية 52% فقط على نفس مجموعة الاختبار. ورغم تحقيقه قيمة Recall مرتفعة بلغت 100% للصورة المكسورة للفئة (0)، إلا أن أدائه كان منخفضاً جداً، حيث لم تتجاوز قيمة الاسترجاع 5%، وانخفضت قيمة F1-score إلى 0.09، مما يشير إلى عدم قدرة النموذج على التعرف على حالات الكسور. وبالتالي يقلل من صلاحيته للاستخدام في التطبيقات الطبية الحساسة.

بالإضافة إلى ذلك، تم تقييم أداء النماذج باستخدام ومنحنى (ROC) مع بيانات غير موزونة والموضح بالشكل (17)، حقق نموذج SVM AUC عند 0.69، مما يدل على أداء أفضل مقارنةً بـ KNN الذي حقق AUC بقيمة 0.55. في المقابل، يبين الشكل (18) أداء النماذج باستخدام ومنحنى (ROC) مع بيانات موزونة، حيث تحسن أداء كلا النموذجين، خاصة في تصنيف الفئة الأقل تمثيلاً، من خلال استخدام بيانات موازنة للفئتين. تؤكد هذه النتائج أن SVM أكثر ملاءمة للتطبيق العملي للنظام المقترح.



شكل 17. منحنى ROC لنموذج (SVM) و (KNN) مع استخراج جميع الميزات من مجموعة بيانات غير متوازنة



شكل 18. منحنى ROC لنموذج (SVM) و (KNN) مع استخراج جميع الميزات من مجموعة بيانات متوازنة

1.4. مقارنة نتائج الدراسة الحالية بالدراسات السابقة

أظهرت نتائج الدراسة الحالية تفوق نموذج SVM بشكل واضح مقارنةً بنموذج KNN، خاصة عند استخدام مجموعة بيانات متوازنة، حيث حقق نموذج SVM أعلى دقة تصنيف بلغت 96% على مجموعة الاختبار، مع قيم مرتفعة لكل من Precision و Recall و F1-score لكلا الفئتين (كسور وغير كسور)، مما يشير إلى إمكانية عالية على تمييز التوازن بين الفئتين. في المقابل، حقق نموذج KNN دقة منخفضة نسبياً بلغت 52%، مع ضعف ملحوظ في استرجاع فئة الكسور، مما يشير إلى محدودية في هذا السياق.

عند مقارنة نتائج هذا البحث بالدراسات السابقة، نلاحظ أن بعض الدراسات التي اعتمدت على نماذج التعلم العميقة، مثل AlexNet و VGG-16 و U-Net و CNN، حققت دقة بنسبة تتراوح بين 89.8% و 96.68%. فعلى سبيل المثال، حققت دراسة Wani و Arora دقة بنسبة 91.1% باستخدام AlexNet، بينما سجلت دراسة Üreten وآخرون دقة 93.3% باستخدام VGG-16، في حين وصلت دقة نماذج CNN للتجزئة إلى 96.68% في دراسة Goel وآخرين.

وبالرغم أن بعض نماذج التعلم العميق حققت دقة أعلى بقليل حوالي (0.68%) من نموذج SVM المستخدم في هذا البحث، إلا أن النتائج الحالية تُعد منافسة وقوية، خاصة عند الأخذ في الاعتبار أن البحث الحالي اعتمد على خوارزميات تعلم آلي تقليدية بدلاً من شبكات العصبية العميقة، والتي تتطلب عادةً موارد حسابية عالية، وبيانات ضخمة، و زمن تدريب أطول. ويعزى التحسن الملحوظ في أداء نموذج SVM في هذا البحث إلى الاعتماد على مرحلة مسبقة فعالة للصور، شملت وتحسين التباين، وتطبيع البيانات، واستخراج ميزات هندسية دقيقة باستخدام عدة خوارزميات منها

VGG-16، مما أسهم في تمثيل أفضل للمعلومات البصرية المهمة المرتبطة بالكسور. كما أن توازن البيانات بين الفئتين، إلى جانب اختيار معاملات مناسبة لنموذج SVM، ساعد في تحقيق أداء مستقر وعالي الدقة. وعليه، يُظهر هذه البحث أن الجمع بين معالجة صور فعالة وخوارزميات تعلم آلي ذكية يمكن أن تحقق نتائج دقيقة وقابلة للتطبيق العملي، مع تقليل التعقيد الحسابي مقارنةً بنماذج التعلم العميق، مما يمثل إضافة علمية مهمة في مجال تشخيص كسور العظام باستخدام صور الأشعة السينية.

5. الاستنتاجات

اعتماداً على النتائج التي تم التوصل إليها، يمكن القول إن استخدام تقنيات الذكاء الاصطناعي والتعلم الآلي في تصنيف كسور العظام قادر على مساعدة الطاقم الطبي على تقليل الوقت والجهد اللازمين لتشخيص كسور العظام. حيث تم التحقق من صحة النتائج تجريبياً، واعتمد تقييم أداء النموذج على عدة مقاييس منها منحني ROC وتقرير التصنيف لتحديد مدى دقة وفعالية النموذج في تصنيف الصور. نسبة النجاح التي بلغت 96% عند استخدام نموذج الـ SVM مع مجموعة بيانات متوازنة تعكس أداءً جيداً كما يُظهر النموذج كفاءته في التمييز بين الصور المكسورة وغير المكسورة حتى عند استخدام بيانات غير متوازنة (بدقة 83.36%). مما يعزز من دقة تشخيص الكسور وبناءً على هذه النتائج فإن من أهم استنتاجات البحث:

- يُعد هذا البحث خطوة هامة نحو تحسين الرعاية الصحية بالاعتماد على خوارزميات وتطبيقات الذكاء الاصطناعي لتشخيص كسور العظام من خلال تحليل صور الأشعة السينية.
- يسهم البحث في تحسين جودة الرعاية الصحية ويقلل من الأخطاء البشرية ويُحسن من نتائج المرضى.
- تؤكد نتائج البحث أن SVM أكثر ملاءمة في التمييز بين صور x-ray لكسور العظام وبكفاءة عالية.
- يساعد البحث على تقليل التحديات التي يواجهها اختصاصيو الأشعة من خلال زيادة دقة التشخيص، وتقليل الوقت اللازم لإجراء التشخيصات. وبالتالي الوصول للتشخيص السريع والمباشر للأطباء وأخصائي الأشعة وتقليل العبء عليهم.
- يوصي هذا البحث على إجراء المزيد من الأبحاث في هذا المجال وتبني هذه التقنيات على نطاق أوسع في الممارسات الطبية اليومية، لتحسين جودة الرعاية الصحية المقدمة للمرضى. وعليه يقترح التالي:
- توسيع نطاق النظام لتشخيص أنواع الكسور المختلفة.



- استخدام نظام مشابه لتشخيص امراض مثل الأورام أو التهابات الرئة اعتمادا على تقنيات معالجة الصور والتعلم الآلي.
- توفير أداة شاملة، باستخدام النظام في تحليل أنواع أخرى من الصور الطبية وتوسيع فائدة النظام باستخدامه في تحليل صور طبية مثل الرنين المغناطيسي (MRI) والأشعة المقطعية (CT scans).

المراجع

أولاً: المراجع باللغة العربية

- ذويب، محمّد (2020). مقدمة عن خوارزمية آلة المتجه الداعم-Support Vector Machine. على الرابط: [\[https://aiinarabic.com/introduction-to-support-vector-machine/\]](https://aiinarabic.com/introduction-to-support-vector-machine/).
- طعيمة، علاء (2020). *التعلم الآلي عن طريق الأمثلة*. كلية علوم الحاسوب وتكنولوجيا المعلومات. جامعة القادسية، العراق.
- عوكل، لمى عدنان (2021). *دور استخدام خوارزميات الذكاء الصناعي في عمليات ضبط الجودة: دراسة حالة-مصنع الميسور للصناعات البلاستيكية-سورية-ريف دمشق*. رسالة ماجستير في إدارة الجودة، الجامعة الافتراضية السورية، سورية.
- قمو، زهرة؛ هويدي، فاطمة سليمان؛ إكحيل، سليمة وكندي، غزالة (2023). دور الأنظمة الإلكترونية في تحسين إدارة ومتابعة مشاريع التخرج عبر الإنترنت: دراسة تطبيقية لكلية تقنية المعلومات. *المؤتمر العلمي السنوي لطلاب المرحلة الجامعية والدراسات العليا بالجامعة الأسمرية الإسلامية*، 1، 35-16-7.

ثانياً: المراجع باللغة الإنجليزية

- Bagaria, R., Wadhwani, S., & Wadhwani, A. K. (2021). Bone fracture detection in X-ray images using convolutional neural network. In Raju Pal & Praveen K. Shukla (eds.), *SCRS Conference Proceedings on Intelligent Systems*, 459–466. Computing & Intelligent Systems, SCRS, India.
- Bhalla, N. (2024). *Hough Transforms in Image Processing*. Scaler. Online at: [\[https://www.scaler.com/topics/hough-transform-in-image-processing/\]](https://www.scaler.com/topics/hough-transform-in-image-processing/).
- Bigham-Sadegh, A., & Oryan, A. (2015). Basic concepts regarding fracture healing and the current options and future directions in managing bone fractures. *International Wound Journal*, 12(3), 238-247.
- Cloudinary (2024). *Median Filter*. Cloudinary. Online at: [\[https://cloudinary.com/glossary/median-filter\]](https://cloudinary.com/glossary/median-filter).
- Goel, M. K., Singh, G., Sunil, G., MuhamedAle, H., & Sharma, G. (2025). Hand Fracture Detection Using Convolutional Neural Networks: A Deep Learning Approach for Automated Diagnostics. In *2025 IEEE International Conference on Interdisciplinary Approaches in Technology and*



- Management for Social Innovation (IATMSI)*, 3, 1-6). IEEE.
- Howedi, F. S., Aldabrzi, A. Y., Sultan, S., & Wali, A. (2023). Utilizing Information Technology Tools to Design and Develop an E-travel Guide System for Tourism Industry -Applied study to the City of Misurata, *Annama Journal (STDJ)*, 4(2), 101-112.
- Mehta, R., Pareek, P., Jayaswal, R., Patil, S., & Vyas, K. (2023). Bone fracture detection using AI-based techniques. *Scalable Computing: Practice and Experience*, 24(2), 161-171.
- Murti, K. C. S. (2022). Use Cases. In *Design Principles for Embedded Systems*, 21-34. Singapore: Springer Singapore.
- Noureen, A., Zia, M. A., Adnan, A., & Hashim, M. (2023). Analysis and classification of bone fractures using machine learning techniques. In *E3S Web of Conferences*, 409, 02015. EDP Sciences.
- Thorat, S. R., Jha, D. G., Sharma, A. K., & Katkar, D. V. (2024). Wrist fracture detection using self-supervised learning methodology. *Journal of Musculoskeletal Surgery and Research*, 8(2), 133-141.
- Towards AI. (2020). *What is a Canny Edge Detection Algorithm?* Towards AI. Online at: [<https://towardsai.net/p/computer-vision/what-is-a-canny-edge-detection-algorithm>].
- Üreten, K., Sevinç, H. F., İğdeli, U., Onay, A., & Maraş, Y. (2022). Use of deep learning methods for hand fracture detection from plain hand radiographs. *Turkish Journal of Trauma & Emergency Surgery*, 28(2), 196-201.
- Vironicka, S. A., & Sathiaselvan, J. G. R. (2022). Framework for Classifying Long Bone Detection Using Image Processing Techniques. *International Journal of Intelligent Systems and Applications in Engineering*, 10(1s), 56–66.
- Wang, R., Wang, J., & Wang, N. (2017). Application of data mining technology in medical image processing. In *2016 International Conference on Engineering and Advanced Technology (ICEAT 2016)*, 18-21. Atlantis Press.
- Wang, X., Xu, Z., Tong, Y., Xia, L., Jie, B., Ding, P., Bai, H., Zhang, Y., & He, Y. (2022). Detection and classification of mandibular fracture on CT scan using deep convolutional neural network. *Clinical Oral Investigations*, 26(6), 4593-4601.
- Wani, I. M., & Arora, S. (2023). Osteoporosis diagnosis in knee X-rays by transfer learning based on convolution neural network. *Multimedia Tools and Applications*, 82(9), 14193-14217.

الملحق: تنفيذ واجهات النظام

أ.1) تنفيذ الواجهة الرئيسية:

من خلال الواجهة الرئيسية للنظام (كاشف) والموضحة بالشكل (19)، يمكن للمستخدم اختيار أحد الخياران إنشاء حساب أو تسجيل الدخول. عند النقر على زر إنشاء حساب، تظهر الواجهة المخصصة لإنشاء الحساب كما بالشكل (20). حيث يطلب من المستخدم إدخال اسمه وكلمة المرور ثم تأكيد كلمة المرور، يعرض النظام رسالة خطأ. حالة إدخال اسم مستخدم موجود مسبقاً.

أ.2) تنفيذ واجهة تحميل صور الأشعة السينية

يمكن للمستخدم الدخول للنظام عن طريق نافذة تسجيل الدخول الموضحة بالشكل (21)، حيث يقوم بإدخال اسم المستخدم وكلمة المرور للانتقال إلى واجهة تحميل وتحليل صور الأشعة كما بالشكل (22)، والتي يمكن من خلالها تحميل صورة الأشعة المطلوب أو تعديل البيانات بعد تحديد اسم المريض المطلوب، أو حذف بياناته، وكذلك طباعة التقارير في حال أراد المريض طباعة معلوماته ونتجه كشف الكسر.

أ.3) تنفيذ واجهة إضافة وتحليل صور أشعة


من الواجهة الموضحة بالشكل (22) يمكن إدخال اسم المريض وإضافة صورة X-ray له بحيث يتم تحميل الصورة المطلوبة كما هو بالشكل (23)، في حال اختيار صورة ليست في المستوى الرمادي، تظهر رسالة خطأ. بعد تحميل الصورة بنجاح يمكن للمستخدم النقر على زر تحليل الصورة لتحليل الصورة من قبل النظام القائم على التعلم الآلي (SVM، KNN) وإظهار النتيجة في المكان المخصص. في حالة وجود كسر تظهر نتيجة تحليل الصورة كما بالشكل (24)، أما في حالة عدم وجود كسر تظهر نتيجة التصنيف كما بالشكل (25). وباختيار زر حفظ يمكن حفظ بيانات المريض والنتيجة والصورة الخاصة به، حيث تظهر رسالة تأكد ذلك.



شكل 20. واجهة إنشاء حساب جديد



شكل 19. الواجهة الرئيسية للنظام



شكل 22. واجهة تحميل وتحليل صور الأشعة السينية




شكل 21. واجهة تسجيل الدخول عند ادخال البيانات



شكل 24. نتيجة تحليل الصورة في حالة وجود كسر (fractured)



شكل 23. تحميل الصورة بنجاح



شكل 25. نتيجة تحليل الصورة في حالة عدم وجود كسر (Non-fractured)