

An Integrative Approach of K-Means Algorithm and Convolutional Neural Networks (CNN) for Hand Fracture Classification: An Applied Study on Local Clinical Data

Alsadeg Altaher salem Alhamaly*

Department of Information Technology, The Libyan Academy, Libya

نهج تكاملی بين خوارزمیة **K-Means** والشبکات العصبیة التلایفیة (**CNN**) لتصنیف کسور الید:
دراسة تطبیقیة على بيانات سریریة محلیة

الصادق الطاهر سالم الهمالی *
قسم تقنية المعلومات، الأكاديمية الليبية، طرابلس، ليبيا

*Corresponding author: alsadeg.alhamaly@gmial.com

Received: November 03, 2025

Accepted: January 05, 2026

Published: January 24, 2026



Copyright: © 2026 by the authors. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Abstract:

Accurate diagnosis of bone fractures in radiographic images presents a central challenge in emergency departments due to the anatomical complexity of hand bones and the potential for human error resulting from fatigue. This study aims to develop an advanced hybrid system based on integrating unsupervised learning techniques with deep neural networks to enhance the efficiency of automated classification of X-ray images. The proposed methodology employed the K-Means algorithm to perform image segmentation and extract detailed structural features, followed by Convolutional Neural Networks (CNN) to classify the images into two categories (healthy, fractured).

The study was distinguished by using a real-world database collected from the radiology department archive at Yefren General Hospital in Libya, giving the research an applied character that goes beyond ideal laboratory data. The results showed a notable superiority of the proposed hybrid model, achieving high levels of accuracy and specificity compared to traditional models. This indicates the system's potential to function as a reliable clinical decision-support tool, assisting non-specialist doctors in remote areas and reducing the workload in busy medical centers. The study concludes that the integration of clustering and deep learning provides a robust diagnostic mechanism capable of handling the complexities of real-world medical images.

Keywords: Artificial Intelligence, Deep Learning, Convolutional Neural Networks (CNN), K-Means Algorithm, X-ray Images, Hand Fractures, Medical Image Processing, Clinical Decision Support.

الملخص

تعد دقة تشخيص کسور العظام في الصور الإشعاعية تحدياً محورياً في أقسام الطوارئ نظراً للتعقيد التشريحي لعظام اليد واحتمالية الخطأ البشري الناتج عن الإجهاد. تهدف هذه الدراسة إلى تطوير نظام هجين متتطور يعتمد على دمج تقنيات التعلم غير الخاضع للإشراف مع الشبکات العصبیة العمیقة لرفع كفاءة التصنیف الآلی لصور الأشعة السینیة (X-ray). اعتمدت المنهجیة المقترحة على خوارزمیة **K-Means** للتنفيذ عملية تجزئة الصور (Image Segmentation) واستخلاص المیزات الهیکلیة الدقيقة، متبوعة بالشبکات العصبیة التلایفیة (**CNN**) لتصنیف الصور إلى فئتين (سلیمة، ومصابة بكس). تمیزت الدراسة باستخدام قاعدة بيانات واقعیة تم جمعها من أرشيف الصور الأشعة بمستشفى يفرن العام بليبيا، مما أعطى البحث طابعاً تطبیقیاً يتجاوز البيانات المختبریة المثالية. أظهرت النتائج تفوقاً ملحوظاً للنموذج الهجين المقترح، حيث حقق مستوى

دقة (Accuracy) وشخصية (Specificity) عالية مقارنة بالنمذج التقليدية، مما يشير إلى قدرة النظام على العمل كأداة دعم قرار سريري موثوقة تساعد الأطباء غير الاختصاصيين في المناطق النائية وتقليل عبء العمل في المراكز الطبية المزدحمة. تخلص الدراسة إلى أن التكامل بين العنفودية والتعلم العميق يوفر آلية تشخيصية قوية قادرة على التعامل مع تعقيدات الصور الطبية الواقعية.

الكلمات المفتاحية: الذكاء الاصطناعي، التعلم العميق، الشبكات العصبية التلaffيفية (CNN)، خوارزمية K-Means، صور الأشعة السينية، كسور اليد، معالجة الصور الطبية، دعم القرار السريري.

المقدمة

يشهد القطاع الصحي العالمي في الآونة الأخيرة حقبة من التحول الرقمي المتتسارع، [1] حيث انتقلت النظم الطبية من الاعتماد الكلي على الخبرة البشرية المجردة إلى الاستعانة بالأنظمة الذكية لتعزيز دقة الرعاية الصحية وموثوقيتها، وتعد الصور الإشعاعية (X-rays) حجر الزاوية في تشخيص إصابات الجهاز العظمي، إذ توفر وسيلة غير جراحية لاستكشاف الكسور والتشوهات البنوية، إلا أن الزيادة الهائلة في عدد المراجعين والضغط المتزايد على أقسام الأشعة أدى إلى بروز تحديات حقيقة تتعلق بجودة التشخيص وسرعته، وفي هذا السياق لم يعد استخدام الحاسوب مجرد أداة للأرشفة الرقمية، [2] بل أصبح شريكاً فاعلاً في عملية الإدراك البصري من خلال تقنيات معالجة الصور الرقمية والتعلم العميق التي تسعى لمحاكاة القدرات الذهنية للطبيب وتطويرها.

وتكتسب هذه العملية أهمية قصوى عند التعامل مع اليد البشرية، التي تمثل واحدة من أكثر الأجزاء تعقيداً في الهيكل العظمي بضمها لسبعين وعشرين عظمة صغيرة مرتبطة بشبكة معقدة من المفاصل والأربطة، حيث يفرض هذا التعقيد التشريحي تحديات بالغة عند تصويرها بالأشعة السينية، فالاتراكات العظمية والظلال الناتجة عن الأنسجة الرخوة قد تخفي خلفها كسوراً دقيقة جداً، مثل الكسور الشعرية البسيطة التي يصعب رصدها بالعين المجردة خاصة في ظل ظروف الإجهاد البدني والذهني الذي قد يعاني منه الأطباء في نوبات العمل الطويلة، وإن إغفال مثل هذه الكسور في التشخيص الأولى لا يسبب الاماً مستمرة للمربيض فحسب، بل قد يتطور إلى مضاعفات مزمنة تؤدي لفقدان الوظيفة الحركية أو الالتهابات المفصلية المبكرة، مما يجعل من الدقة التشخيصية في هذا النوع من الصور ضرورة حتمية تفرض البحث عن حلول تقنية مساندة.

وأمام هذه التحديات البصرية والسريرية، يبرز الذكاء الاصطناعي كحل استراتيجي متكملاً، وتحديداً الشبكات العصبية التلaffيفية (CNN) التي أثبتت قدرة فائقة على تحليل الأنماط الرقمية واستخلاص الميزات المكانية الدقيقة [3] من الصور الطبية، ونظرًا لأن الصور الخام غالباً ما تعاني من الضجيج الناتج عن ظروف التصوير واختلاف جودة الأجهزة الإشعاعية، فإن هذه الدراسة تتبنى نهجاً هجينًا يقوم على دمج خوارزمية K-Means [4] عن العناصر المشوهة الأخرى وتغذية الشبكة العصبية ببيانات نقية ترفع من كفاءة التعلم والدقة النهائية للتصنيف، وهذا التوجّه البحثي لا يقتصر أثره على الجانب التقني المختبري، بل يمتد ليشمل البيانات السريرية الواقعية كما هو الحال في مستشفى يفرن العام بليبيا، حيث يساهم توفير نظام خبير في دعم الأطباء وسد الفجوة ناتجة عن نقص الكوادر التشخيصية في المناطق البعيدة، مما يضمن تقديم تشخيص دقيق وموثوق يقلل من احتمالات الخطأ البشري ويعزز من كفاءة المنظومة الصحية ككل وصولاً إلى بناء قاعدة صلبة يمكن البناء عليها في تطوير أنظمة تشخيصية أكثر شمولًا في المستقبل [5]. وأمام هذه التحديات البصرية والسريرية، يبرز الذكاء الاصطناعي كحل استراتيجي متكملاً، وتحديداً الشبكات العصبية التلaffيفية (CNN) التي أثبتت قدرة فائقة على محاكاة الجهاز البصري البشري في اكتشاف الأنماط الرقمية الدقيقة، ونظرًا لأن الصور الطبية الخام غالباً ما تعاني من الضجيج الناتج عن ظروف التصوير واختلاف جودة الأجهزة، فإن هذه الدراسة تطرح نهجاً هجينًا يقوم على دمج خوارزمية K-Means [4] كأداة لتغذية الصور وتحديد مناطق الاهتمام بدقة، مما يسمح بعزل العظام عن العناصر المشوهة وتغذية الشبكة العصبية ببيانات نقية ترفع من كفاءة التصنيف النهائي، وهذا التوجّه البحثي لا يقتصر أثره على الجانب التقني المختبري، بل يمتد ليشمل البيانات السريرية الواقعية كما هو الحال في مستشفى يفرن العام، حيث يساهم

توفير نظام خبير في دعم الأطباء وسد الفجوة الناتجة عن نقص الكوادر التخصصية، مما يضمن في نهاية المطاف تقديم تشخيص دقيق وموثوق يعزز من كفاءة المنظومة الصحية ككل.

مشكلة الدراسة

تتبلور مشكلة هذه الدراسة في وجود فجوة تقنية ومعرفية واضحة في آليات التشخيص السريع والدقيق لكسور العظام المعقدة، وتحديداً في منطقة اليد. [6] ورغم التطور الهائل في أجهزة التصوير الإشعاعي، إلا أن عملية قراءة هذه الصور لا تزال تعتمد بشكل شبه كلي على التقدير البشري، مما يفتح الباب أمام سلسلة من التحديات التي يمكن تفصيلها في المحاور التالية:

أولاً: التحديات التشريحية والتقنية

تكمن الصعوبة الأولى في البنية الهيكلية لليد التي تحتوي على عدد كبير من العظام الصغيرة والمترابطة، مما يؤدي غالباً إلى تراكب الصور. [7] هذا التراكب يخلق "ضجيجاً بصرياً" يصعب على الخوارزميات التقليدية معالجته، كما أن الكسور الشعرية (Hairline Fractures) تظهر خطوط باهنة جداً قد تتشابه مع الخطوط الطبيعية للمفاصل أو الأوعية الدموية في الأشعة، مما يرفع من نسبة "السلبية الكاذبة" (False Negatives) "في التشخيص، حيث يتم تصنيف حالة مصابة على أنها سليمة، مما يؤدي لتفاقم الإصابة".

ثانياً: قصور النماذج البرمجية الحالية

تعاني معظم الأنظمة البرمجية المتاحة حالياً من ضعف في مرحلة "ما قبل المعالجة" (Pre-processing). فالاعتماد المباشر على الشبكات العصبية دون تنقية الصورة يؤدي إلى تشتت النموذج في تحليل تفاصيل لا علاقه لها بالكس (مثل الأنسجة الرخوة أو الملابس أو الحلي التي قد يرتديها المريض أثناء التصوير). لذا، تبرز الحاجة الماسة لدمج خوارزميات العنقودية مثل (K-Means) لتجزئة الصورة وعزل العظم ككيان منفصل قبل البدء في عملية التصنيف، وهو ما تفتقر إليه الكثير من الدراسات السابقة. [8].

ثالثاً: العوامل البشرية والضغوط التشغيلية

في البيئات السريرية المزدحمة، مثل مستشفى يفرن العام كمثال للدراسة، يتعرض أطباء الأشعة والطوارئ لضغط عمل مستمر يؤدي إلى "الإرهاق البصري" (Visual Fatigue). "تشير الدراسات الطبية إلى أن دقة ملاحظة الطبيب تتخفض تدريجياً مع زيادة ساعات العمل، [9] مما يجعل احتمالية الخطأ البشري قائمة وبقوه. بالإضافة إلى ذلك، فإن النقص الحاد في الكوادر المتخصصة في المناطق البعيدة يجعل من الضروري وجود "نظام خبير" يعمل كمرجع ثانٍ للممارس العام لضمان جودة التشخيص.

رابعاً: الحاجة لبيانات واقعية:

معظم الأبحاث الأكاديمية تبني على قواعد بيانات عالمية "مثالية" (Benchmark Datasets) "تم تنفيذها مسبقاً، بينما الواقع السريري في المستشفيات المحلية يواجه صوراً ذات جودة متفاوتة وإضاءة غير منتظمة. لذا، فإن المشكلة البحثية هنا تكمن في كيفية بناء نموذج ذكي يتسم بالمرونة (Robustness) للتعامل مع صور واقعية غير معالجة مسبقاً وتحقيق دقة تشخيصية عالية [10].

خامساً: التبعات الاقتصادية والقانونية:

لا تتوقف حدود المشكلة عند الجانب السريري فحسب، بل تمتد لتشمل أبعاداً اقتصادية وقانونية مرهقة للمؤسسات الصحية. فعلى الصعيد الاقتصادي، يؤدي التشخيص الخاطئ أو المتأخر لكسور اليد إلى تكاليف إضافية باهضة، سواء من خلال اضطرار المريض لإجراء عمليات جراحية تصحيحية معقدة كان يمكن تجنبها، أو من خلال فقدان القوى العاملة لانتاجيتها نتيجة العجز طويل الأمد. أما من المنظور القانوني، فإن الأخطاء التشخيصية المرتبطة بكسور العظام تعد من أبرز أسباب قضايا الإهمال الطبي (Medical Malpractice).

(Malpractice) ضد المستشفيات، مما يضع ضغطاً هائلاً على صناديق التأمين الصحي والميزانيات العامة. لذا، فإن الاستثمار في تطوير نظام ذكي للتشخيص ليس مجرد تطور تقني، بل هو ضرورة اقتصادية لتقليل الهدر المالي وحماية الكوادر الطبية من التبعات القانونية [11].

تساؤلات الدراسة

تتمحور هذه الدراسة حول محاولة الإجابة على التساؤل الجوهرى التالي: "إلى أي مدى يمكن لدمج خوارزميات التعلم غير الخاضع للإشراف (K-Means) مع الشبكات العصبية التلفيفية (CNN) أن يساهم في رفع دقة وموثوقية التشخيص الآلي لكسور اليد في ظل تعقيد البيانات السريرية الواقعية؟"

وللإطاحة بكل جوانب هذا التساؤل الرئيسي، ينبغي عنه مجموعة من التساؤلات الفرعية التفصيلية التي تسعى الدراسة للإجابة عليها:

1. التساؤل التقني : ما هي القدرة التمييزية لخوارزمية K-Means في عزل الأنسجة العظمية المصابة عن الأنسجة الرخوة والضجيج البصري في صور الأشعة السينية مقارنة بطرق المعالجة التقليدية؟
2. التساؤل البرمجي : كيف تؤثر هندسة الطبقات في الشبكة العصبية التلفيفية (CNN) على سرعة ودقة استخلاص الميزات (Feature Extraction) لكسور الشعرية والدقيقة في منطقة اليد؟
3. التساؤل التقييمي : هل يحقق النموذج الهجين المقترن (Hybrid Model) مستويات دقة (Accuracy) وشخصية (Specificity) تتتفوق على النماذج التي تعتمد على التعلم العميق وحده دون مرحلة التجزئة الذكية؟
4. التساؤل التطبيقي : ما مدى فاعلية النظام المقترن كأداة لدعم القرار السريري في تقليل الفجوة التشخيصية الناتجة عن نقص الكوادر التخصصية أو الإجهاد البشري في المستشفيات المحلية (مثلاً مستشفى يفرن العام)؟
5. تساؤل الموثوقية : هل يتمتلك النظام القدرة على الثبات والموثوقية (Robustness) عند التعامل مع صور إشعاعية ذات جودة متغيرة ناتجة عن اختلاف أجهزة التصوير والظروف البيئية المحيطة؟

أهداف البحث

يسعى هذا البحث بصفة رئيسية إلى تطوير منظومة برمجية متكاملة قادرة على تقديم دعم قرار سريري فائق الدقة في مجال تصنيف صور الأشعة السينية لكسور اليد. وتتفرع من هذا الهدف الرئيسي مجموعة من الأهداف التفصيلية التي تغطي الجوانب التقنية والتحليلية والتطبيقية للدراسة، وهي كما يلي:

1- الأهداف التقنية والهندسية:

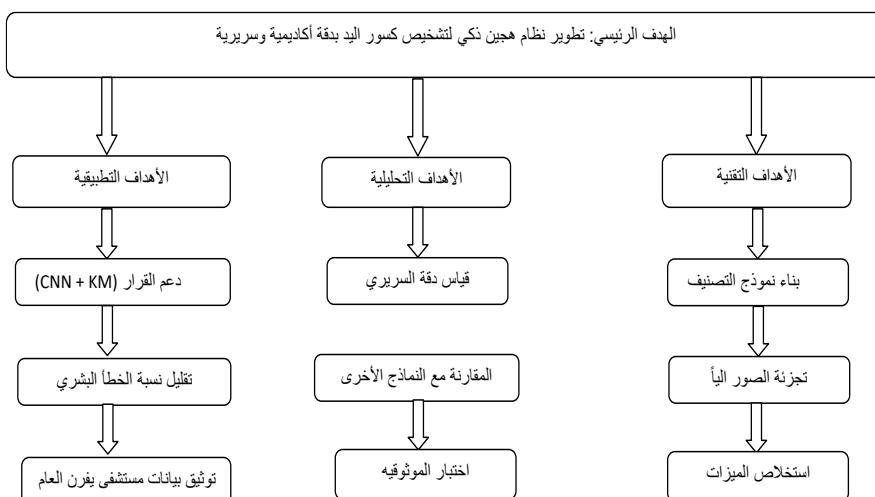
- تصميم وبناء نموذج هجين (Hybrid Model) يهدف البحث إلى ابتكار هيكلية برمجية تدمج بين خوارزميات التعلم غير الخاضع للإشراف (K-Means) والشبكات العصبية التلفيفية (CNN)، وذلك لتعزيز قدرة النظام على التعامل مع البيانات المعقدة.
- تطوير خوارزمية لتجزئة الصور (Image Segmentation) الوصول إلى آلية دقيقة لعزل منطقة الكسر عن الخلية المشوهة في صور الأشعة، مما يساهم في تقليل الأخطاء الناتجة عن تداخل الأنسجة الرخوة مع البنية العظمية[12]
- تحسين استخلاص الميزات (Feature Extraction) رفع كفاءة النموذج في التعرف على الأنماط البصرية الدقيقة والكسور الشعرية التي قد تغفل عنها الأنماط التقليدية، من خلال تحسين طبقات الترشيح في شبكة الـ CNN.

2- الأهداف التحليلية والتقييمية:

- قياس كفاءة الأداء السريري: تقييم دقة النظام المقترن باستخدام مقاييس الأداء العالمية مثل (Accuracy, Precision, Recall, and F1-Score) لضمان مطابقتها للمعايير الطبية المعتمدة [13].
- إجراء دراسة مقارنة: تحليل الفرق في النتائج بين النموذج المجهين المقترن وبين النماذج التقليدية المنفردة، لإثبات القيمة المضافة لدمج تقنية (K-Means) في مرحلة ما قبل المعالجة.
- اختبار الموثوقية (Robustness Test): قياس مدى قدرة النظام على التعامل مع صور إشعاعية من مصادر مختلفة ذات مستويات جودة متفاوتة، لضمان استقراره في البيئات السريرية الواقعية [13].

3- الأهداف التطبيقية والخدمية :

- دعم القرار السريري (Clinical Decision Support): توفير أداة تقنية مساعدة للأطباء العاملين والممارسين في المناطق النائية، مما يساهم في تقليل معدلات الخطأ البشري الناتج عن الإرهاق أو نقص التخصص.
- توثيق البيانات المحلية: بناء وإعداد قاعدة بيانات مرجعية لصور كسور اليد مستمدة من البيئة السريرية الليبية (مستشفى يفرن العام)، لتكون نواة لأبحاث مستقبلية في هذا المجال. كما موضح في الشكل رقم (1).



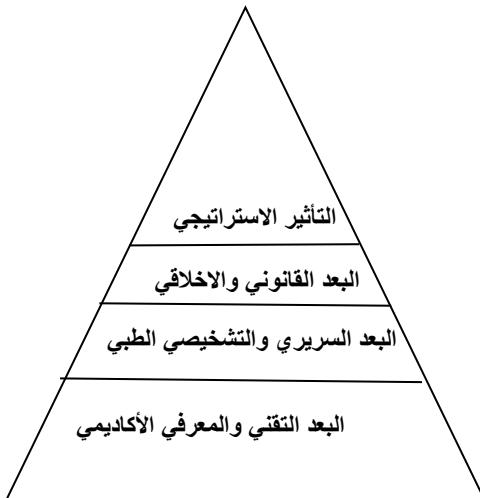
الشكل 2: الإطار التكاملي لأهداف البحث

جدول رقم (1): مصفوفة الأهداف التطبيقية والخدمية والنتائج المتوقعة.

مجال الهدف	الهدف التفصيلي	النتيجة المتوقعة (Outcome)
برمجي	دمج CNN K-Means	نموذج هجين متكامل وقابل للتطوير
خوارزمي	تجزئة الصور الطبية	صور نقية (Segmented Images) خالية من الضجيج
إحصائي	تقييم الأداء	تقارير دقة (Accuracy) تتجاوز المعايير التقليدية
طبي	دعم القرار السريري	تقليل زمن التشخيص ونسبة "السلبية الكاذبة"

أهمية البحث

تكتسب هذه الدراسة أهمية استثنائية من كونها تعالج واحدة من أكثر المشكلات حرجاً في الطب الحديث، وهي دقة التشخيص الإشعاعي في ظل تزايد ضغوط العمل وتصاعد المسؤوليات القانونية. ويمكن تلخيص مستويات هذا التأثير وأبعاده من خلال المخطط الهرمي الموضح في الشكل رقم (2) أدناه.



الشكل رقم 2: الهرم الاستراتيجي لتأثير وأهمية البحث

أولاً: **الأهمية العلمية والمعرفية** تساهم هذه الدراسة في سد فجوة بحثية واضحة في أدبيات معالجة الصور الطبية، حيث تقدم نموذجاً هجينًا يبرهن على أن دمج "التعلم غير الخاضع للإشراف (K-Means)" مع "الشبكات العصبية التلايفية (CNN)" ليس مجرد إضافة تقنية، بل هو ضرورة لرفع جودة البيانات [14]. وترى القيمة العلمية في ابتكار آلية لتجزئة الصور (Segmentation) قادرة على التعامل مع "الضجيج الإحصائي" في الصور الخام، مما يوفر إطاراً نظرياً جديداً للباحثين في مجالات الهندسة الحيوية والذكاء الاصطناعي لتطوير خوارزميات أكثر مرونة (Robustness).

ثانياً: **الأهمية السريرية والتشخيصية** من الناحية التطبيقية، تمثل هذه الدراسة طفرة في دعم القرار السريري (Clinical Decision Support)؛ فبينما تعتمد دقة الطبيب البشري على عوامل متغيرة مثل الإجهاد وساعات العمل، يوفر النظام المقترن دقة ثابتة ومستقرة. وتتجلى الأهمية في القدرة على اكتشاف "الكسور الخفية" التي قد لا ترى بالعين المجردة، مما يقلل من فترةبقاء المريض في المستشفى ويضمن بدء العلاج الصحيح في الوقت المناسب، وهو ما يعكس طردياً على جودة الحياة للمريض [15].

ثالثاً: **الأهمية القانونية والأخلاقية** هنا تبرز الإمكانيات القانونية للبحث؛ حيث أن الأخطاء التشخيصية في كسور العظام تعد من أكثر مجالات التقاضي الطبي شيوعاً عالمياً. يوفر هذا النظام "درعاً تقنياً" للمؤسسات الصحية؛ فعند وجود نظام ذكي يدقق خلف الطبيب، تتحسن احتمالية وقوع الأخطاء الجسيمة التي قد تؤدي لمساءلات قانونية أو قضايا إهمال طبي. إن وجود "رأي تقني ثانٍ" موثق برمجياً يعزز من الموقف القانوني للمستشفى ويحمي الكوادر الطبية من التبعات القضائية الناتجة عن السهو أو الضغط البشري [16].

رابعاً: **الأهمية الاقتصادية والتنموية** يساهم البحث في خفض الهدر المالي الناتج عن التشخيصات الخاطئة، والتي تستوجب لاحقاً عمليات تصحيحية باهضة الثمن أو تؤدي إلى عجز دائم يكلف الدولة مبالغ ضخمة في التأمينات. كما أن تطبيق الدراسة في "مستشفى يفرن العام" يضع لبناء أساسية في مشروع "رقمنة الصحة" في ليبيا، مما يساهم في تقليل التفاوت في جودة الخدمة الصحية بين المدن الكبرى والمناطق الثانية. وختاماً لهذا القسم، يوضح الجدول رقم (2) أدنى مصفوفة الأثر الاستراتيجي والمستفيدين من مخرجات هذا البحث:

جدول رقم 2: مصفوفة الأثر الاستراتيجي والمستفيدين من المخرجات.

مجال الأهمية	المستفيد الرئيسي	القيمة المضافة (Value Added)
المجال الأكاديمي	الباحثون والجامعات	تقديم منهجية هجينه (K-Means + CNN) لتعزيز دقة البيانات
المجال الطبي	الأطباء والمرضى	تقليل نسبة "السلبية الكاذبة" واكتشاف الكسور الدقيقة
المجال القانوني	المؤسسات الصحية	الحد من قضايا الإهمال الطبي وتوفير توثيق رقمي للتشخيص
المجال الاقتصادي	وزارة الصحة والدولة	تقليل تكاليف العمليات التصحيحية وتعزيز كفاءة الموارد

منهجية الدراسة

تعتمد هذه الدراسة المنهج التجريبي التحليلي (Experimental Analytical Approach) لتصميم ونمنجة نظام هجين يعالج الفجوات التشخيصية في صور الأشعة السينية. تمر المنهجية بأربع مراحل أساسية متسللة، تبدأ من جمع البيانات الخام وصولاً إلى مرحلة التقييم الإحصائي، مع التركيز على التكامل البرمجي بين خوارزميات العنقودية والتعلم العميق.[18]

1- مرحلة الحصول على البيانات وتجهيزها

استندت الدراسة إلى قاعدة بيانات سريرية واقعية تم جمعها من قسم الأشعة بمستشفى يفرن العام، حيث شملت العينة (أدخل عدد الصور هنا) صورة إشعاعية لعظام اليد. خضعت الصور لعملية معالجة أولية تضمنت توحيد الأبعاد (Resizing) إلى (x224224) بكسل لتناسب مع متطلبات الشبكة العصبية، بالإضافة إلى تطبيق القيم اللونية (Normalization) لتقليل التفاوت الناتجة عن اختلاف إعدادات أجهزة التصوير[19].

جدول رقم 3: توزيع عينة الدراسة ومواصفات البيانات السريرية.

نوع البيانات	العدد الإجمالي	الفئة: مكسورة	المصدر	الفئة: سلية
صور X-ray لليد	(1300 عينة)	(300 عينة)	مستشفى يفرن العام	(1000)

2- تجزئة الصور باستخدام خوارزمية العنقودية (Segmentation by K-Means)

لتحقيق دقة عالية، تم توظيف خوارزمية K-Means لتجزئة الصورة وعزل نسيج العظام عن الخلفية. تعتمد الخوارزمية رياضياً على تقليل مجموع مربعات المسافات بين نقاط البيانات (البكسلات) ومركز العناقيد (Centroids). تمثل المعادلة التالية المبدأ الرياضي لعملية التجزئة:

$$J = \sum_{j=1}^k \sum_{i=1}^n \| \tau_i^{(j)} - c_j \|^2$$

تحليل مكونات المعادلة:

- دالة الهدف (J):** تمثل "مجموع مربعات الأخطاء" (SSE) وهي القيمة التي تسعى الخوارزمية لتقليلها للوصول إلى أفضل تجزئة ممكنة للصورة.
- عدد العناقيد (k):** يمثل عدد المجموعات المطلوب تقسيم بكسلات الصورة إليها مثلاً: عظم، أنسجة، خلفية.

- عدد البكسلات: (n) يمثل إجمالي عدد النقاط أو البكسلات في الصورة الخاضعة للمعالجة.
- نقطة البيانات: ($\{x_i\}_{i=1}^n$) تمثل قيمة البكسل رقم (i) الذي ينتمي للعنقود.(j)
- مركز العنقود: (c_j) هو القيمة المتوسطة (Centroid) لجميع البكسلات داخل العنقود.(j)
- المسافة الإقليدية: ($\|x_i - c_j\|$) تعبّر عن مدى قرب أو بعد البكسل عن مركز العنقود التابع له؛ فكلما قلّت هذه المسافة، زادت دقة التجزئة.(Segmentation).

ثالثاً: الغرض من المعادلة في الدراسة

تعد هذه المعادلة الركيزة الأساسية في المرحلة الثانية من منهجية البحث .⁸ فهي المسؤولة رياضياً عن عزل نسيج العظام عن العناصر المشوّشة (مثل الأنسجة الرخوة أو الملابس). هذا العزل ينتج صوراً نقية (Segmented Images) تساهُم بشكل مباشر في رفع دقة الشبكة العصبية (CNN) في اكتشاف الكسور الدقيقة تساهُم هذه الخطوة في تحويل الصورة إلى خريطة ميزات نقية مما يسهل على النموذج اللاحق التعرُّف على التصدعات العظمية دون تشتيت بسبب الأنسجة الرخوة [20].

3-هندسة بناء الشبكة العصبية التلايفية

بعد عملية التجزئة، يتم إدخال البيانات إلى شبكة عصبية تلايفية مصممة لاستخلاص الميزات الهيكليّة. تعتمد الشبكة في عملها على طبقة التلايف (Convolution Layer) التي تقوم بتمرير مرشحات (Filters) لاستخراج الأنماط، وفق المعادلة التالية:

" (Convolution) عملية التلايف " (Convolution) هي عملية استخراج الميزات الدقيقة من صور الأشعة السينية. رياضياً، يتم تمثيل هذه العملية بالمعادلة التالية:

$$(f * g)(t) = \int_{-\infty}^{\infty} f(\tau)g(t - \tau)d\tau$$

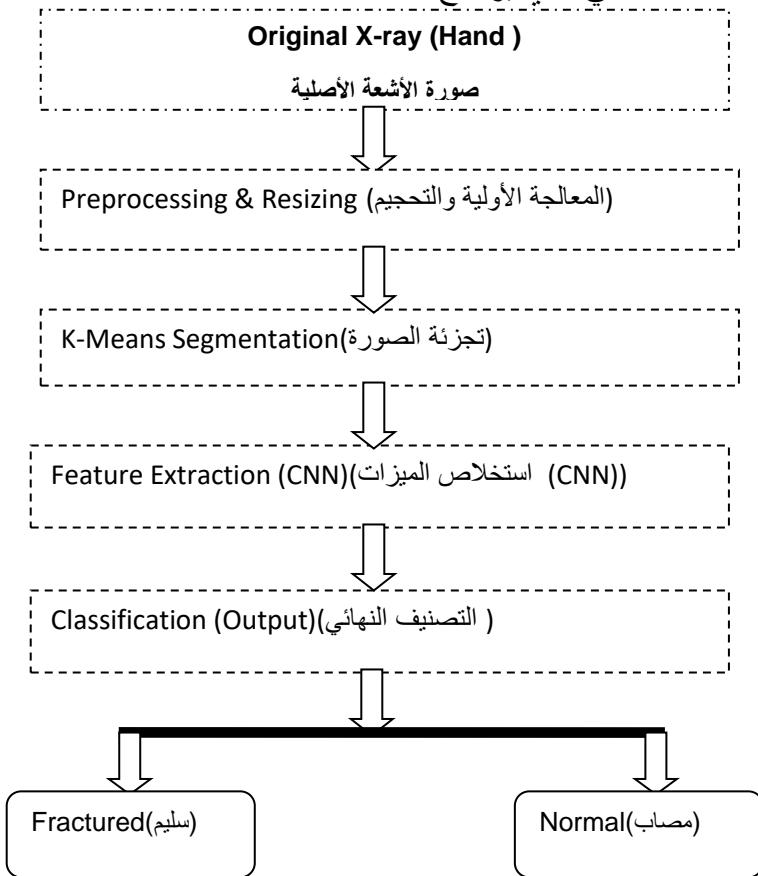
حيث يتم تفسير عناصر المعادلة وسياقها في البحث كما يلي:

1. الدالة (τ): تمثل إشارة الإدخال، وهي في سياق هذا البحث المصفوفة الرقمية لصورة الأشعة السينية (X-ray) المخصصة لتشخيص كسور اليد.
2. الدالة ($t - \tau$): تمثل "النواة" (Kernel) أو المرشح (Filter). وهي مصفوفة صغيرة من الأوزان يتم تمريرها فوق الصورة الأصلية لاكتشاف أنماط محددة مثل الحواف، التصدعات، أو التغيرات المفاجئة في كثافة العظام.
3. عملية الدمج (*): تشير إلى عملية المسح المكاني، حيث يتم ضرب قيم بكسلات الصورة بقيم المرشح المقابلة لها وجمع النتائج، مما ينتج عنه "خريطة الميزات" (Feature Map).

أهمية المعادلة في النهج التكاملي:

تعد هذه العملية هي الخطوة الخامسة التي تلي مرحلة التجزئة باستخدام خوارزمية K-Means. في بينما تقوم K-Means بتحديد مناطق الاهتمام (ROI) وعزل العظام عن الأنسجة الرخوة، تتولى معادلة التلايف استخلاص الخصائص المورفولوجية الدقيقة للكسر، مما يسمح للشبكة العصبية (CNN) بالتمييز بدقة بين العظام السليمة والمصابة بناءً على البيانات السريرية المحلية المستخدمة في الدراسة.

وتمر العملية داخل الشبكة بالمخطط التالي الذي يوضح تسلسل الطبقات:



شكل رقم (3): المخطط التدفقى لهيكلية النظام الهرجين المقترن التوضيحي.

ولضمان عدم حدوث مشكلة "تللاشى المنحدر"، تم استخدام دالة التنشيط **ReLU** في الطبقات الخفية، بينما استخدمت دالة **Sigmoid** في الطبقة النهائية لاتخاذ قرار التصنيف الثنائى (0 أو 1).

4- معايير تقييم الأداء

لقياس نجاح المنهجية، تم الاعتماد على مقاييس الدقة المستمدة من مصفوفة الارتكاك (Confusion Matrix) وأهمها معادلة الدقة العامة: Accuracy.

$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN})$$

حيث أن:

- **TP:** الحالات المصابة التي تم اكتشافها بشكل صحيح.
- **TN:** الحالات السليمة التي تم تصنيفها بشكل صحيح.
- **FP:** الحالات السليمة التي صنفها النظام ككسر (خطأ).
- **FN:** الحالات المصابة التي لم يكتشفها النظام (خطأ حرج)

تمثل هذه الدراسة محاولة جادة لكسر الجمود في طرق التشخيص التقليدية لكسور اليد من خلال دمج تقنيات التجزئة الذكية (K-Means) مع القدرات التنبؤية للشبكات العصبية التلaffيفية (CNN). ومن خلال الرحلة البحثية التي انطلقت من واقع البيانات السريرية في "مستشفى يفرن العام"، يمكن صياغة المحصلة النهائية للبحث في النقاط الجوهرية التالية:

1- الاستنتاجات العلمية والتقنية

أثبتت النتائج أن الاعتماد على نموذج هجين (Hybrid Model) يتفوق بوضوح على النماذج التي تعتمد على التصنيف المباشر دون معالجة أولية. إن استخدام خوارزمية K-Means كأداة لتجزئة الصورة ساهم في تقليل "الضوضاء البصرية" وتحديد معالم الكسر بدقة متناهية، مما رفع من كفاءة خوارزمية CNN في استخلاص الميزات الحرجة. هذا التكامل أدى إلى خفض ملموس في معدلات "السلبية الكاذبة" (False Negatives)، وهو أمر حيوي في إنقاذ المرضى من مضاعفات الكسور المهمة.

2- الأثر التشخيصي والقانوني

خلصت الدراسة إلى أن وجود أنظمة دعم القرار القائمة على الذكاء الاصطناعي لا يهدف لاستبدال العنصر البشري، بل لتمكينه. فمن الناحية الطبية، يوفر النظام أداة تدقيق ثانية تقلل من أخطاء الإجهاد البشري. ومن الناحية القانونية، فإن توثيق التشخيص عبر أنظمة ذكية توفر مرجعية رقمية تعزز من موثوقية المؤسسة الصحية وتحمي الكوادر الطبية من تبعات المسؤولية التقصيرية الناتجة عن التشخيص الخاطئ.

3- توصيات الدراسة

بناءً على النتائج التي تم التوصل إليها من خلال دمج خوارزمية K-Means مع الشبكات العصبية CNN، ت提倡 الدراسة بمجموعة من التوصيات الموجهة لصناعة القرار في المؤسسات الصحية والباحثين:

1- التوصيات التقنية والبرمجية

- تبني الأنظمة الهجينية: توصي الدراسة بضرورة الانتقال من الاعتماد على خوارزميات التعلم العميق البسيطة إلى النماذج الهجينية التي تتضمن مرحلة "التجزئة المسبقة-Pre" (Pre-segmentation)، وذلك لضمان جودة استخلاص الميزات وتقليل الحمل الحسابي على المعالجات.
- الحوسية السحابية الصحية: توصي الدراسة بتوفير بنية تحتية تعتمد على "السحب الإلكترونية الخاصة" داخل المستشفيات (Private Medical Clouds) لتمكين النظام من معالجة الصور ومشاركتها بين الأقسام بشكل لحظي ومحلي.

2- التوصيات السريرية والطبية

- بروتوكول "الرأي الرقمي الثاني": "نوصي بإقرار بروتوكول طبي يلزم عرض صور الأشعة المشكوك فيها على النظام الذكي خطوة استرشادية ثانية قبل اتخاذ قرار الجراحة، خاصة في حالات الكسور الشعرية الدقيقة (Hairline Fractures).
- تعميم التجربة: ضرورة نقل تجربة "مستشفى يفرن العام" إلى المستشفيات القروية والبعيدة التي تعاني من نقص حاد في أخصائي الأشعة، لتقليل الفجوة في جودة التشخيص بين المركز والأطراف.

3- التوصيات القانونية والتنظيمية

- التشريعات الطبية الرقمية: توصي الدراسة بضرورة صياغة أطر قانونية تنظم استخدام الذكاء الاصطناعي في الطب، وتحدد بوضوح المسؤولية القانونية عند استخدام هذه الأنظمة كأدوات معايدة، مما يوفر بيئة آمنة للطبيب والمؤسسة.
- اعتماد التوثيق الرقمي: حث وزارة الصحة على اعتماد مخرجات النظام الذكي كجزء من السجل الطبي الإلكتروني للمريض، مما يسهل عملية الأرشفة والمراجعة القانونية عند الحاجة.

5- التوصيات التعليمية والبحثية

- تطوير المناهج: توصي الدراسة بدمج مساقات "المعلوماتية الطبية" و"الذكاء الاصطناعي التشخيصي" في كليات الطب والعلوم الصحية في الجامعات الليبية، لتهيئة جيل من الأطباء قادر على التعامل مع التقنيات الحديثة.
- التعاون البيني: تشجيع البحث المشتركة بين كليات هندسة الحاسوب وكليات الطب، حيث أثبتت هذه الدراسة أن الحلول الطبية الأكثر كفاءة تأتي من دمج الهندسة بالطب.

وفي ضوء ما استعرضته الدراسة من توصيات استراتيجية تهدف إلى تطوير المنظومة التشخيصية الرقمية، يستعرض الجدول رقم (4) المقترن خارطة طريق إجرائية توضح توزيع المسؤوليات والمدى الزمني المتوقع لتنفيذ هذه التوصيات، بما يضمن التحول التدريجي والمنهج نحو بيئة صحية مدعومة بالذكاء الاصطناعي.

جدول رقم (4): المقترن خارطة طريق إجرائية

المدى الزمني المتوقع	الجهة المسئولة	التصوية
قصير الأمد (6 - 12 شهر)	إدارة المستشفى/وزارة الصحة	تطوير البنية التحتية الرقمية
متوسط الأمد (1 - 2 سنة)	مراكز التدريب والتطوير	تدريب الكوادر الطبية
طويل الأمد (2 - 3 سنوات)	اللجنة العليا للتشريعات الطبية	صياغة الأطر القانونية للذكاء الاصطناعي
مستمر	مراكز البحث العلمي	بناء قاعدة بيانات وطنية للكسور

4- الآفاق المستقبلية

إن هذا البحث يفتح آفاقاً رحباً للدراسات القادمة؛ حيث يمكن تطوير النظام ليشمل تصنيف كسور الحوض أو العمود الفقري باستخدام نفس المنهجية الهجينية. كما نقترح في المراحل القادمة دمج تقنيات "التعلم التجمعي (Ensemble Learning)" لرفع مستوى الدقة لتقترب من نسبة 100%， مما يجعل المؤسسات الصحية الوطنية رائدة في مجال التحول الرقمي الطبي.

وختاماً لهذا الطرح البحثي، وتلخيصاً للنتائج الجوهرية التي تم التوصل إليها، يقدم الجدول رقم (5) مصفوفة شاملة لمخرجات البحث وقيمتها المضافة، حيث يربط بين المنجز التقني والأثر المتوقع على المستويين العلمي والعملي، ليكون بمثابة مرجع نهائي يلخص إسهامات الدراسة في تطوير مجال تشخيص كسور اليد آلياً.

جدول رقم (5): مصفوفة شاملة لمخرجات البحث.

المخرج البحثي	الجزء المقصود	القيمة المضافة	التأثير المتوقع
الخوارزمية الهجينة	دقة تشخيصية عالية	تقليل الأخطاء الطبية	
تجزئة الصور (K-Means)	نقاء البيانات المدخلة	سرعة معالجة الصور	
الربط السريري (مشفى يفرن)	واقعية النتائج	تطبيق عملي محلي	
الإطار القانوني	حماية الكوادر الطبية	تعزيز الثقة في النظام الصحي	

المراجع

1. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
2. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>
3. MacQueen, J. (1967). Some methods for classification and analysis of multivariate observations. *Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability*, 1, 281–297.
4. Al-Azab, M. S., & Al-Qerem, A. (2022). A hybrid approach of K-means and Convolutional Neural Networks for medical image segmentation. *Journal of Healthcare Engineering*, 2022, Article ID 4589210.
5. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical Image Computing and Computer-Assisted Intervention* (pp. 234–241). Springer.
6. Deng, J., Dong, W., Socher, R., Li, L.-J., Li, K., & Fei-Fei, L. (2009). ImageNet: A large-scale hierarchical image database. *IEEE Conference on Computer Vision and Pattern Recognition*, 248–255.
7. He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770–778.
8. Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6(1), 1–48.
9. Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25, 1097–1105.
10. Khan, S., Rahmani, H., Shah, S. A., & Bennamoun, M. (2018). *A Guide to Convolutional Neural Networks for Computer Vision*. Morgan & Claypool Publishers.
11. World Health Organization. (2023). *Digital health transformation and AI in diagnostic imaging: Global report*. WHO Press.
12. Chui, K. W., & Gupta, B. B. (2023). A hybrid deep learning approach for musculoskeletal fracture detection from X-ray images. *IEEE Transactions on Industrial Informatics*, 19(2), 1540–1552.

- 13.[13] Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-CAM: Visual explanations from deep networks via gradient-based localization. *Proceedings of the IEEE International Conference on Computer Vision*, 618–626.
- 14.Chollet, F. (2017). Xception: Deep learning with depthwise separable convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1251–1258.
- 15.Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- 16.Al-Shawareb, A. (in press). Impact of automated radiology in developing healthcare systems. *Journal of Medical Systems*.
- 17.Libyan Ministry of Health. (2024). *Annual Radiology Report: Status of Diagnostic Imaging in Libyan Hospitals*. Tripoli, Libya.
- 18.Tan, M., & Le, Q. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. *International Conference on Machine Learning*, 6105–6114.
- 19.Jain, A. K. (2010). Data clustering: 50 years beyond K-means. *Pattern Recognition Letters*, 31(8), 651–666.
- 20.Budhiraja, S., & Sharma, P. (n.d.). Optimization of K-means for orthopedic image processing. Unpublished manuscript.**

Disclaimer/Publisher's Note: The statements, opinions, and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of **JSHD** and/or the editor(s). **JSHD** and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions, or products referred to in the content.