

Using Deep Learning and Particle Swarm Optimization Algorithm to Recognize Fatty Liver in Compressed Images

Mousa Al-hasan Omar^{1,*}, Ali Ukasha¹ 

¹Department of Electrical and Electronic Engineering, Engineering Faculty, Wadi Alshatti University, Brack Alshatti, Libya

ARTICLE HISTORY

Received 11 January 2025
Revised 10 February 2025
Accepted 14 February 2025
Online 27 February 2025

KEYWORDS

Neural network (Autoencoders);
Fatty liver;
Singular value decomposition;
Particle swarm optimization
algorithm;
Medical image processing;
Deep learning;

ABSTRACT

With the increasing rates of liver steatosis and fibrosis, the need for accurate and rapid diagnostic tools for these conditions using medical imaging has become pressing. This study aims to develop a deep learning-based model for analyzing and diagnosing liver steatosis from compressed medical images, with performance enhancement using the Particle Swarm Optimization (PSO) algorithm. To improve the efficiency of the analysis process and reduce diagnostic costs, the Singular Value Decomposition (SVD) technique was employed for image compression, contributing to data size reduction while preserving the essential image quality. The proposed model relies on an Autoencoder Network supported by the PSO algorithm to enhance image quality after compression and was implemented using MATLAB software. Previous studies demonstrated the effectiveness of PSO in improving analysis accuracy, achieving 92.2% accuracy, an F-Score of 87.2%, and an Intersection over Union (IoU) of 90.7%. In the current study, the results showed that the developed model achieved higher performance, with an accuracy of 94.81%, an F-Score of 97.34%, and a Jaccard Index of 94.81%. Additionally, the model successfully reduced image sizes by 45% with a low execution time of approximately 6.27 seconds, without compromising the quality of the medical analysis. This model represents a promising tool in non-invasive medical imaging for studying liver diseases, enhancing the speed and accuracy of diagnosis, assisting physicians in making informed clinical decisions, and reducing the costs and risks associated with traditional diagnostic methods.

استخدام التعلم العميق وخوارزمية تحسين سرب الجسيمات للتعرف على الكبد الدهني في الصور المضغوطة

موسى الحسن عمر^{1,*}، علي عبدالرحمن عكاشة¹

المخلص	الكلمات المفتاحية
في ظل تزايد معدلات الإصابة بدهنية الكبد والتليف الكبدي، أصبحت الحاجة ملحة لتطوير أدوات دقيقة وسريعة لتشخيص هذه الحالات باستخدام الصور الطبية. تهدف هذه الدراسة إلى تطوير نموذج يعتمد على التعلم العميق لتحليل وتشخيص دهنية الكبد من الصور الطبية المضغوطة، مع تعزيز الأداء باستخدام خوارزمية تحسين سرب الجسيمات (PSO). لتحسين كفاءة عملية التحليل وتقليل التكاليف المرتبطة بالتشخيص تم استخدام تقنية تحليل القيمة المفردة (SVD) لضغط الصور، مما يساهم في تقليل حجم البيانات مع الحفاظ على الجودة الأساسية للصورة. يعتمد النموذج المقترح على شبكة ترميز تلقائي (Auto-Encoder Network) مدعومة بخوارزمية PSO لتحسين جودة الصورة بعد ضغطها، وتم تنفيذ النموذج باستخدام برنامج MATLAB. أثبتت الدراسات السابقة فعالية PSO في تحسين دقة التحليل، حيث حققت دقة بلغت 92.2%، مع F-Score بنسبة 87.2% و Jaccard بنسبة 90.7%. أما في الدراسة الحالية، فقد أظهرت النتائج أن النموذج المطور حقق أداءً أعلى مع دقة وصلت إلى 94.81%، ودرجة F بنسبة 97.34%، ودرجة Jaccard بنفس النسبة 94.81%. إضافةً إلى ذلك، تمكن النموذج من تقليل حجم الصور بنسبة 45% مع وقت تنفيذ منخفض بلغ حوالي 6.27 ثانية، دون التأثير على جودة التحليل الطبي. يمثل هذا النموذج أداة واعدة في التصوير الطبي غير الجراحي لدراسة أمراض الكبد مما يعزز سرعة ودقة التشخيص، ويساعد الأطباء في اتخاذ قرارات سريرية مستنيرة، بالإضافة إلى تقليل التكاليف والمخاطر المرتبطة بالتشخيص التقليدي.	الشبكة العصبية (Autoencoders) الكبد الدهني تحليل القيمة المفردة (SVD) خوارزمية تحسين سرب الجسيمات (PSO) معالجة الصورة الطبية التعلم العميق

المقدمة

سرطانية محتملة إذا لم تتم معالجتها بشكل كافٍ [1]. يشمل تصنيف هذا المرض فئتين متميزتين: مرض الكبد الدهني الكحولي، الذي ينشأ عن الاستهلاك المفرط للإيثانول، ومرض الكبد الدهني غير الكحولي (NAFLD) هو موضوع الدراسة، والذي يُعزى إلى الاستهلاك المفرط للأغذية إلى جانب عدم كفاية النشاط البدني [2].

يعد مرض الكبد الدهني من الأمراض المنتشرة عالمياً، إذ يعاني منه عدد كبير من الأفراد حول العالم. ويتسم هذا المرض، وخاصة في شكله غير الكحولي، بتراكم الدهون بشكل مفرط داخل خلايا الكبد. قد يؤدي تراكم الدهون هذا إلى حدوث استجابات التهابية وتغيرات ليفية وضعف وظيفي للكبد وتحولات

الدراسات السابقة

قدم Seyed Muhammad وآخرون (2022) نظام يعتمد على تقنيات متعددة لمعالجة الصور لتحديد مستوى الدهون في الكبد باستخدام أربع علامات تشخيصية. تم توظيف أربع تقنيات تقسيم هي: تقنية عتبة (Otsu)، وفصل المياه (Watershed)، وتقنية (K Means)، وتحسين أسراب الجسيمات (PSO) لتحديد مستوى الاضطراب لهذا المرض. وقد تم تقييم دقة النظام المقترح باستخدام مقاييس الأداء Accuracy و F-Score و IoU أو Jaccard، مما أظهر أداءً مرضياً عند مقارنته بالطرق التقليدية. أظهرت النتائج دقة متوسطة للنظام بمعدل 92.2% لجميع العينات مقارنةً بالبيانات المرجعية، فيما كانت قيم مقاييس الأداء Jaccard و F-Score هي 87.2% و 90.7% على التوالي [3]. وفي عام (2019) قدم (Xiaoyuan Guo وآخرون) دراسة حول القياس الكمي الدقيق لمنطقة التنكس الدهني داخل صور الفحص المجهرية لأنسجة الكبد حيث يعتبر مهماً في تشخيص أمراض الكبد. في هذه الدراسة تم استخدام طريقة التعلم العميق لحل مشكلة تجزئة التنكس الدهني للكبد. نظراً لعدم وجود قطرات التنكس الدهني المسعى من صور الفحص المجهرية للكبد للتدريب، حيث قاموا بتعديل طريقة تجزئة النوى السابقة لتوليد بيانات تدريب تنكس دهني للكبد بعد عملية فحص فعالة بواسطة خبير المجال، حيث يتم استخدام نموذج التعلم العميق Mask-RCNN لتقسيم قطرات التنكس الدهني في كتل. الممتد من أسرع R-CNN، يمكن لـ Mask-RCNN التنبؤ بأقنعة الكائنات بالإضافة إلى اكتشاف الصندوق المحيط. باستخدام التعلم بالنقل (Transfer Learning)، يكون النموذج الناتج قادراً على تقسيم مناطق التنكس الدهني المتداخلة عند 75% حسب متوسط الدقة، و 66.60% بواسطة Recall، و 65.88% حسب درجة F1، و 76.97% بواسطة مؤشر Jaccard. تشير التقييمات الكمية إلى أن تقنية التعلم العميق تمكن من تجزئة تنكس دهني دقيقة وعالية الأداء، وهي أداة وأداة لتعزيز تشخيص أمراض الكبد [6].

بينما في 2022 قدم Bhupathi, D وآخرون دراسة تكتشف مدى دقة التعلم الآلي في التنبؤ بأمراض الكبد. تقدم هذه الدراسة طريقة التنبؤ بأمراض الكبد (LDP) والتي يمكن أن يستخدمها المتخصصون في مجال الصحة وأصحاب المصلحة والطلاب والباحثون. تم اختيار خمس خوارزميات، وهي آلة الدعم المتجه (SVM)، وخوارزمية بايز الساذجة، وخوارزمية (K-NN)، وخوارزمية التحليل التمييزي الخطي (LDA)، وخوارزمية التصنيف والانحدار (CART). تتم مقارنة الدقة لاكتشاف أفضل طريقة تصنيف للتنبؤ بأمراض الكبد باستخدام Python و R. ومن خلال النتائج، حصلت K-NN على أفضل دقة بنسبة 91.7%، وحققت شبكة التشفير التلقائي دقة بنسبة 92.1%، وهي أعلى من المستوى المقبول للدقة ويمكن اعتبارها للتنبؤ بأمراض الكبد [22].


تحليل القيمة المفردة (Singular Value Decomposition)

تحليل القيمة المفردة (SVD) هي تقنية أساسية في الجبر الخطي والإحصاء، يتم تطبيقها على نطاق واسع لتقليل الأبعاد وضغط البيانات حيث تقرب SVD مصفوفة كبيرة بمصفوفة أصغر مع الاحتفاظ بالمعلومات الأساسية وتجاهل التفاصيل الأقل أهمية، وأيضاً تقليل الضوضاء في معالجة الإشارات تقوم SVD بتصفية الضوضاء من خلال التركيز على القيم والمتجهات المفردة المهمة. يقوم تحليل القيمة المفردة بتحليل مصفوفة إلى ثلاث مصفوفات، مما

في الوقت الحالي، يمكن أن يعزى انتشار هذه الحالة إلى الإفراط في تناول السعرات الحرارية والعجز في المجهود البدني، مما يؤدي إلى عدم كفاية التمثيل الغذائي للدهون وترسب الدهون الكبدية لاحقاً. لا تزال خزعة الكبد المعيار التشخيصي النهائي لهذه الحالة؛ ومع ذلك، فإنها تتميز بالتكلفة الكبيرة والمخاطر المرتبطة بها. وبالتالي، هناك طلب متزايد على منهجيات موثوقة وغير جراحية لتشخيص ومراقبة مرض الكبد الدهني. في هذا الصدد، أسفرت التطورات في تقنيات معالجة الصور عن نتائج مشجعة في تشخيص وتقييم هذا المرض، على الرغم من أن خوارزميات تجزئة الصور التقليدية تواجه في كثير من الأحيان تحديات تتعلق بالدقة المنخفضة والمتطلبات الحسابية الكبيرة [2,3]. حيث في السنوات الأخيرة، أثبتت منهجيات التعلم العميق فعاليتها في معالجة الدقيقة والفعالة وتحليل بيانات التصوير الطبي. يهدف هذا البحث إلى تطوير نموذج تعلم عميق يعتمد على خوارزمية تحسين سرب الجسيمات (PSO) لتعزيز دقة تحديد الدهون الكبدية عن طريق التصوير الطبي للصور المضغوطة، وبالتالي تسهيل النتائج الصحية والتخفيف من تطور المرض.

المنهجية

تعتمد هذه المنهجية على التقييم التحليلي للصور الكبدية باستخدام بنية الشبكة العصبية القائمة على الترميز التلقائي (Autoencoder)، معززة بخوارزمية تحسين السرب الجزيئي (PSO) لتعزيز الدقة والموثوقية. تبدأ العملية بدمج صورة الكبد في النظام، حيث تتم المعالجة الأولية بهدف زيادة جودتها وتسهيل استعدادها للتحليل اللاحق. وبعدها، تخضع الصورة لمرحلة ضغط لتقليل حجم البيانات، وبالتالي تبسيط المعالجة وتقليل المدة المطلوبة للتحليل ومن ثم يتم تنشيط الشبكة العصبية التلقائية (AE)، والتي تتمثل مهمتها في تحديد الأنماط واستخراج الميزات البارزة داخل الصورة. في هذه المرحلة، تم استخدام خوارزمية تحسين سرب الجسيمات (PSO) لتعزيز دقة إعدادات الشبكة ومعاملاتها بعد الانتهاء من التدريب، يتم تقييم النموذج باستخدام بيانات جديدة لم يتم دمجها خلال مرحلة التدريب لتقييم فعاليتها بشكل مستقل في حالات التنبؤ. ومن ثم يتم حساب مقاييس الأداء للتأكد من دقة النموذج وفعاليتها. في المرحلة النهائية، يتم وضع النتائج جنباً إلى جنب مع التقييمات التي أجراها متخصصون في مجال أمراض الكبد للتحقق من موثوقية ودقة تحليل النظام كما هو مبين في الشكل 1 للطريقة المقترحة.



الشكل 1: مخطط انسيابي للطريقة المقترحة

يكشف عن خصائص مهمة للمصفوفة الأصلية [7].

خوارزمية تحسين سرب الجسيمات (PSO)

إن منهجية تحسين سرب الجسيمات (PSO) هي نهج ميتاهيورستي (Metaheuristic Method) قائم على السكان ومعترف به على نطاق واسع ويستخدم لمعالجة تحديات التحسين. تحاكي هذه الخوارزمية الديناميكيات الاجتماعية التي تظهرها الأنواع الطيرية داخل القطيع من أجل تحقيق هدف تحديد القوت. من خلال دمج التجارب الفردية والجماعية، تنتقل مجموعة من الطيور نحو مصدر غذائها. إنهم يراجعون مواقعهم باستمرار، متأثرين بموقعهم الشخصي الأمثل والموقع العلوي للسرب بأكمله، وبالتالي إعادة تنظيم أنفسهم في تكوين مثالي. خدم هذا السلوك الاجتماعي والنفسي الملحوظ في الطيور كحافز لراسل إيرهارت (مهندس كهربائي) وجيمس كينيدي (عالم نفس اجتماعي) لاستخدام مفهوم التفاعل الاجتماعي هذا في مجال حل المشكلات. ابتكر كينيدي وإبرهات [8] تقنية تحسين سرب الجسيمات (PSO) خصيصاً لتعزيز تحسين الوظائف غير الخطية المستمرة. تعمل خوارزمية ذكاء السرب المستوحاة من الطبيعة هذه من خلال عمليات تكرارية [15]. تبدأ هذه الطريقة بمجموعة من الحلول المرشحة (تسمى سرباً). وفي هذا السياق، يشير كل جسيم إلى حل محتمل للمشكلة المحددة. وخلال كل تكرار، يخضع هذا المجتمع لتحديثات تتضمن تعديل سرعة وموضع كل جسيم فردي. وتستند هذه التعديلات إلى أفضل قيمة شخصية (pbest) وأفضل قيمة عالمية (gbest). وقد حدد إيرهارت وكينيدي pbest وgbest باعتبارهما القيمتين الأساسيتين. وفي إطار pbest، تتأثر الجسيمات بموضعها الخاص، بينما في إطار gbest، تتأثر مواضع الجسيمات بالموضع الأمثل الذي اكتشفه أي عضو في المجتمع بأكمله. وبعد ذلك، يتقارب كل جسيم نحو هذا الموضع الذي تم تحديده حديثاً، [16] يمكن تعريف pbest على أنه الموضع أو الموقع الأمثل الذي حققه الفرد نفسه حتى الآن. وعلى العكس من ذلك، يمثل gbest الموضع الأمثل الذي حققه أي فرد داخل المجتمع بأكمله أثناء عملية الاستكشاف داخل مساحة البحث عن الحلول [9].

الشبكة العصبية (Autoencoders)


يمثل المشفر التلقائي فئة من الشبكات العصبية الاصطناعية المستخدمة لاستخلاص ترميزات البيانات بطريقة غير خاضعة للإشراف (Unsupervised). والهدف الأساسي للمشفر التلقائي هو الحصول على تمثيل (ترميز) منخفض الأبعاد للبيانات عالية الأبعاد، وذلك في المقام الأول لغرض تقليل الأبعاد، من خلال توجيه الشبكة لتغليف المكونات الأكثر بروزاً في صورة الإدخال. تشكل المشفرات التلقائية مجموعة فرعية متخصصة من الخوارزميات القادرة على تعلم التمثيلات الفعالة لبيانات الإدخال دون الحاجة إلى معلومات مُسمّاة. تم تصميم هذه الفئة من الشبكات العصبية الاصطناعية بدقة لغرض التعلم غير الخاضع للإشراف (Unsupervised) [10,11]. يعتمد المبدأ الأساسي للمفكك التلقائي على القدرة على ضغط بيانات الإدخال وترميزها بشكل فعال في غياب تسميات محددة. يتم تنفيذ ذلك من خلال بنية متفرعة تتألف من مشفر وفك تشفير. يحول المشفر بيانات الإدخال إلى تمثيل منخفض الأبعاد، يشار إليه عادةً باسم "المساحة الكامنة" أو "الترميز". بعد هذا التمثيل، يقوم جهاز فك التشفير بإعادة بناء المدخلات الأصلية. ولكي تتمكن الشبكة من تمييز الأنماط ذات المغزى داخل البيانات، تعمل عمليات التشفير وفك التشفير على تحديد السمات

الأساسية [10,11].

تتضمن البنية العامة لجهاز التشفير التلقائي طبقة التشفير وفك التشفير وطبقة عنق الزجاجة.

المشفر: الطبقة الأولية به مسؤولية عن الحصول على بيانات الإدخال غير المعالجة. تعمل الطبقات المخفية اللاحقة على تقليل أبعاد الإدخال بشكل منهجي، وبالتالي تمثيل الميزات والأنماط الأساسية. بشكل جماعي، تشكل هذه الطبقات المشفر. تُظهر الطبقة المخفية الطرفية، والتي يشار إليها باسم طبقة عنق الزجاجة (المساحة الكامنة)، أبعاداً مخفضة بشكل ملحوظ. تجسد هذه الطبقة التمثيل المضغوط للبيانات الواردة [12].

عنق الزجاجة (Bottleneck): هو وحدة تخزين تمثيلات المعرفة المضغوطة وهو المكون الأكثر أهمية في الشبكة كما هو موضح في الشكل [12,13]. فك التشفير: تقوم طبقة عنق الزجاجة بتحويل التمثيل المشفر مرة أخرى إلى أبعاد الإدخال الأصلية. تزيد الطبقات المخفية من أبعادها تدريجياً بهدف إعادة بناء الإدخال الأصلي. تولد طبقة الإخراج المعاد بناؤه، والذي من الناحية المثالية يجب أن يكون قريباً من بيانات الإدخال قدر الإمكان [14].



الشكل 2: البنية الأساسية للمشفر التلقائي

خلال مرحلة التدريب، تكون دالة الخسارة المستخدمة عبارة عن خسارة إعادة بناء، والتي تقيس التناقض بين المدخلات الأصلية والمخرجات المعاد بناؤها. في سياق البيانات المستمرة، يتم استخدام خطأ التربيع المتوسط (MSE) بشكل متكرر يتم تطبيق الإنتروبيا الثنائية المتقاطعة على البيانات الثنائية. طوال عملية التدريب، تم تصميم Autoencoder لتقليل خسارة إعادة البناء، وبالتالي تمكين الشبكة من تمثيل الميزات الأكثر صلة ببيانات الإدخال داخل طبقة عنق الزجاجة [10].

النتائج

توضح الصورة المقدمة الأنسجة الكبدية كما تمت ملاحظتها من خلال المجهر. عند فحص مورفولوجيتها، يُظهر النسيج ترتيباً ثابتاً للخلايا الكبدية، وهي المكونات الخلوية السائدة للأنسجة الكبدية. تُستخدم هذه الصور بشكل شائع في البحوث الطبية الحيوية والممارسات التشخيصية، لا سيما في تحديد التغييرات التي يمكن أن تشير إلى حالات مرضية مثل التليف أو التهاب

إيجابية مقارنة بالحالات الإيجابية التي صنفها النموذج على أنها إيجابية. تعمل الدقة كمؤشر على موثوقية النموذج في التنبؤ بوجود حالة إيجابية، وبالتالي التأكيد على ضرورة التخفيف من النتائج الإيجابية الكاذبة، وخاصة في مجال التشخيص الطبي [20].

$$Precision = \frac{True\ positives}{True\ positives + False\ positives} \quad (4)$$

• معامل Dice

يُستخدم معامل الزرد لتقييم مدى تشابه منطقتين، ويُستخدم غالبًا لتحديد دقة التجزئة في الصور الطبية. ويكون معامل الزرد مرتفعًا عندما تكون المنطقتان متطابقتين أو متداخلتين بشكل كبير [21].

$$Dice = \frac{True\ positives \times 2}{True\ positives + False\ positives + False\ Negatives \times 2} \quad (5)$$


• معامل Jaccard

يعتبر مؤشرًا دقيقًا للتشابه بين منطقتين، وغالبًا ما يُستخدم في تقسيم الصور الطبية لأنه يعطي نسبة أكثر دقة للتداخل مقارنة بمعامل Dice [21].

$$Jaccard = \frac{True\ positives}{True\ positives + False\ positives + False\ Negatives} \quad (6)$$

تحقيق نسبة ضغط تبلغ 45% يوضح فعالية خوارزمية تحسين سرب الجسيمات في تقليل أبعاد بيانات تصوير الكبد الدهني مع الحفاظ على المعلومات الأساسية ذات الصلة بالتحليل الطبي، مما يمثل تقدمًا كبيرًا في معالجة واستخدام التصوير الطبي.

الحفاظ على مساحة التخزين بعد تحقيق هذا الضغط يقلل من متطلبات سعة التخزين، وبالتالي تسهيل إدارة مجموعات كبيرة من الصور الطبية والحفاظ على الموارد وبدوره يتم تقليل حجم البيانات وبالتالي يعكس الوقت المطلوب لنقل الصور عبر أنظمة وشبكات متنوعة، وبالتالي زيادة الكفاءة التشغيلية.




الشكل 4: سلوك دالة فقدان النموذج (loss function)

يوضح الرسم التوضيحي ديناميكيات وظيفة دالة الخسارة المرتبطة

الكبد.

تُستخدم الدقة والحساسية ومقياس F والدقة ومعامل Jaccard بشكل واسع لتقييم فعالية نماذج التعلم العميق وخوارزميات التصنيف، لا سيما في سياق تحليل الصور الطبية، بما في ذلك اكتشاف الاضطرابات الكبدية. فيما يلي توضيح لكل من هذه المعايير التقييمية [17].



الشكل 3: أنواع الصور المختلفة المستخدمة للكبد [3]

• الدقة (Accuracy)

حيث تشير الدقة إلى نسبة العينات التي تم تصنيفها بشكل صحيح من إجمالي العينات [17].

$$Accuracy = \frac{\text{عدد العينات الصحيحة}}{\text{اجمالي عدد البيانات}} \quad (1)$$

• الحساسية (Sensitivity) أو الاسترجاع (Recall)

يشير هذا المعيار إلى نسبة الحالات الإيجابية مقارنة بالعدد الإجمالي للحالات الفعلية. يعرف أيضًا بمعدل اكتشاف الإيجابيات. حيث يُعد هذا المعيار مهمًا جدًا في التطبيقات الطبية، حيث يشير إلى قدرة النموذج على اكتشاف الحالات المرضية بشكل صحيح. الحساسية العالية تعني أن النموذج يُخطئ قليلًا في تجاهل الحالات الإيجابية [18].

$$Sensitivity = \frac{True\ Positives}{True\ Positives + False\ Negatives} \quad (2)$$

• مقياس (F-Score)

تُعد درجة F مقياسًا متناغمًا للدقة والحساسية، حيث تجمع بين الاثنين لتوفير تقييم أكثر توازنًا، خاصةً عندما يكون هناك تناقض بين الدقة والحساسية. يُعتبر مفيدًا جدًا عندما يكون من الضروري الموازنة بين اكتشاف الحالات الإيجابية بدقة (الحساسية) وتجنب التصنيفات الخاطئة (الدقة) [19].

$$F - Score = 2 \times \frac{Recall \times Precision}{Recall + Precision} \quad (3)$$

• الدقة المثالية (Precision)

يشير مصطلح الدقة إلى نسبة الحالات التي تم تحديدها بدقة على أنها

إلى جودة بصرية عالية للصورة المضغوطة، وهو ما يدعم موثوقية التحليل كما هو موضح في الجدول (2).

الجدول 2: PSNR و SSIM

	SSIM value	Binary Cross-Entrop	P_S_N_R
healthy live	1.0000	0.7829	dB26.1906
Liver in developed (nodular) cirrhosis	1.0000	0.9060	24.625 dB
Liver in developed (nodular) cirrhosis1	0.9994	0.7297	20.7300 dB
Liver in developed (nodular) cirrhosis2	1.0000	0.7980	23.7356 dB
Liver in early chirrosi	0.9977	0.9336	18.9961 dB
Liver in early chirrosi1	0.9994	0.7014	16.5246 dB

• وظائف اللياقة (fitness) وزمن التنفيذ

أظهرت النتائج أن النموذج يحقق سرعة عالية في التنفيذ مع قيم منخفضة لمؤشر (RMSE) حيث سجلت حالة Cirrhosis2 أقل قيمة RMSE عند 0.0081 مع وقت تنفيذ 6.27 ثانية فقط، مما يعكس كفاءة خوارزمية PSO في تحسين المعلمات وتقليل عدد التكرارات اللازمة للوصول إلى الحل الأمثل حيث يلخص الجدول (3) التالي نتائج وظائف اللياقة وزمن التنفيذ.

الجدول 3: مقاييس وظائف اللياقة (fitness) وزمن التنفيذ

	Execution Time	Convergence Rate	fitness Function Value (Final RMSE)
healthy liver	9.1935sec	40 iterations	0.0126
Liver in developed (nodular) cirrhosis	7.3893 sec	28 iterations	0.0091
Liver in developed (nodular) cirrhosis1	5.9935 sec	29 iterations	0.0107
Liver in developed (nodular) cirrhosis2	11.5685sec	2 iterations	0.0116
Liver in early chirrosi	6.2751 sec	3 iterations	0.0081
Liver in early chirrosi1	5.4202 sec	4 iterations	0.0133

تبرز النتائج فعالية الطريقة المقترحة في التعرف على حالات دهنية الكبد

بخوارزمية تحسين سرب الجسيمات (PSO) عبر التكرارات المختلفة. تحدد المحور الأفقي عدد التكرار، بينما يشير المحور العمودي خطأ مربع متوسط الجذر (RMSE)، والذي يعمل كمؤشر على دقة النموذج في سياق ضغط الصور.

في البداية، أثناء التكرارات لوحظ أن قيمة RMSE مرتفعة نسبياً (حوالي 0.022)، مما يدل على أن دقة النموذج ليست كافية بعد. مع تقدم التكرارات، تُظهر قيمة RMSE انخفاضاً تدريجياً ومتسلسلاً، مما يعكس التحسين التدريجي في فعالية النموذج. تصل قيمة RMSE إلى حد منخفض ومستقر بعد حوالي 100 تكرار، حيث يصبح النموذج قادراً على تحقيق أداء ثابت ولا يظهر تحسن كبير بعد هذه النقطة. تؤكد هذه الظاهرة فعالية خوارزمية PSO في زيادة أداء النموذج خلال التكرار إذ تعمل الخوارزمية على تقليل الخطأ تدريجياً، مما يزيد من دقة ضغط الصور دون التأثير الكبير على جودة الصور.

حيث تظهر نتائج الأداء في هذه الدراسة فعالية خوارزمية تحسين سرب الجسيمات (PSO) في تحسين دقة وضغط صور دهنية الكبد باستخدام التعلم العميق. مما يساهم في تقليل حجم البيانات وتبسيط عمليات إدارة الصور ونقلها دون التأثير السلبي على جودة المعلومات المهمة للتحليل.

• أداء الجسيمات والنماذج:

أفضل الجسيم: كان الجسيم رقم 6 هو الأفضل في العديد من التكرارات، حيث حقق أدنى قيمة لدالة الهدف بلغت 0.0121، مما يعكس كفاءته العالية في تحسين أداء النموذج.

يوضح الجدول (1) القيم المختلفة لمقاييس أداء نموذج التحليل، حيث تم تحقيق نتائج عالية في جميع المؤشرات كما يلي.

الجدول 1: القيم المختلفة لمقاييس أداء نموذج التحليل

الدقة (Accuracy)	الحساسية (Sensitivity)	مؤشر (Dice)	مؤشر (Jaccard)	مقياس (F-score)
94.81%	94.81%	97.34%	97.34%	94.81%


توضح هذه النتائج أن النموذج يمتاز بكفاءة عالية في التنبؤ والتصنيف. حيث الجذر التربيعي لمتوسط الخطأ (RMSE) بلغ قيمة منخفضة وصلت إلى 0.01208، مما يعكس قدرة النموذج على تقديم تنبؤات دقيقة وتقليل الأخطاء. يظهر سلوك RMSE في الرسم البياني انخفاضاً ثابتاً عبر التكرارات، مما يشير إلى تحسن الأداء التدريجي نتيجةً للتكرارات المتتالية.

أداء خوارزمية PSO يُظهر الرسم البياني انخفاضاً مستمراً في RMSE مع زيادة عدد التكرارات، مما يؤكد قدرة PSO على تحسين النموذج بشكل متكرر وإيجاد الحلول المثلى لتقليل أخطاء الضغط.


تشير هذه النتائج مجتمعة إلى أن استخدام التعلم العميق مع خوارزمية PSO يمكن أن يوفر تحسينات كبيرة في تحليل الصور المضغوطة لدهنية الكبد، مما يساهم في تحسين التشخيص والعلاج في المجال الطبي، ويجعل هذه التقنية أداة فعالة في مجال التصوير الطبي الدقيق.

• جودة الصور المضغوطة PSNR و SSIM

حققت الصور المضغوطة قيماً عالية في مؤشر التشابه البنيوي (SSIM)، حيث بلغت 1.0 في معظم الحالات، مما يدل على الحفاظ التام على الخصائص الهيكلية للصورة بعد الضغط. أما مؤشر نسبة الإشارة إلى الضوضاء (PSNR)، فقد تراوح بين 16.5246 dB و 26.1906 dB مما يشير



الشكل 5: مقارنة عدة مقاييس عبر ثلاث دراسات



الشكل 6: منحنى ROC للنموذج.

الشكل (6) يوضح أن منحنى ROC للنموذج (الخط المنحني) أعلى من خط المصنف العشوائي، مما يشير إلى أن النموذج لديه قدرة جيدة على التمييز بين الفئتين. كلما كانت المساحة تحت المنحنى (ROC) أكبر، كان أداء النموذج أفضل.

- **True Positive Rate (TPR):** يشير إلى قدرة النموذج على الكشف الصحيح عن الحالات الإيجابية (مرضى الكبد الدهني).
 - **False Positive Rate (FPR):** يعكس نسبة الحالات السلبية التي تم تصنيفها بشكل خاطئ كإيجابية.
- النموذج يظهر قدرة عالية على التمييز بين الفئات (مثل الحالات السليمة مقابل الحالات المصابة).

المساحة تحت المنحنى (AUC - Area Under Curve) تعتبر مؤشراً لأداء النموذج. يُمكن أن تصل دقة النموذج إلى 0.94.

نظراً لعدم توفر أخصائي في علم أمراض الكبد في ليبيا، قمنا بالاعتماد على الورقة البحثية السابقة التي استخدمت تقنيات متقدمة لتحليل وتشخيص مرض الكبد الدهني كأساس لتقسيم البيانات وتصنيفها إلى حالتين مصابة وسليمة. بعد بناء النموذج المعتمد على الصور الطبية المضغوطة، تمت مقارنة أداء النموذج مع تصنيف الأخصائي باستخدام المؤشرات الإحصائية مثل منحنى ROC. كما يظهر في منحنى ROC في الشكل (6)، فإن أداء النموذج كان مقارباً لتصنيف الأخصائي، حيث سجل النموذج قدرة تمييز

باستخدام الصور المضغوطة. أظهر النظام قدرة عالية على تحقيق توازن بين دقة النتائج وسرعة التنفيذ، مع الحفاظ على جودة الصور المضغوطة. هذه المنهجية تمثل تقدماً كبيراً في استخدام تقنيات التعلم العميق والضغط في التشخيص الطبي، مما يجعلها أداة واعدة لتحسين دقة وسرعة التشخيص.

الجدول 4: مقارنة المقاييس بين الدراسات السابقة

المقياس	الدراسة الحالية	دراسة 2022 [3]	دراسة 2019 [6]
Accuracy	0.944	0.922	0.758
Sensitivity	0.934	#	0.606
F-score	0.966	0.872	0.658
Precision	1.00	#	#
Dice	0.966	#	#
Jaccard	0.934	0.907	0.769
Compression Ratio	50-0.49	#	#
Execution Time	11-5	#	#

الجدول (4) يعرض مقارنة بين أداء الدراسة الحالية ودراسات سابقة أجريت في عامي 2022 و2019 بناءً على مجموعة من المعايير التي تُستخدم لتقييم أداء النماذج أو الخوارزميات. تشمل هذه المعايير الدقة (Accuracy)، والحساسية (Sensitivity)، ومؤشر (F-score)، والدقة المثالية (Precision)، ومؤشر Dice، ومؤشر Jaccard، ونسبة الضغط (Compression Ratio)، ووقت التنفيذ (Execution Time). الدراسة الحالية حققت أداءً متفوقاً في معظم هذه المعايير مقارنة بالدراسات السابقة، حيث سجلت دقة أعلى بلغت 0.944 مقارنة بدراسة 2022 التي حققت 0.922، بينما تظهر دراسة 2019 دقة 0.758. بالنسبة للحساسية، حققت الدراسة الحالية 0.934، مقارنة بدراسة 2022 لم يستخدموا المقياس، بينما تظهر دراسة 2019 حساسية 0.606.

فيما يخص مؤشر F، قدمت الدراسة الحالية نتيجة مرتفعة جداً بلغت 0.966، وهو أعلى بكثير من دراسة 2022 التي سجلت 0.872، ومن دراسة 2019 التي أظهرت قيمة أقل بكثير 0.658. كذلك، أظهرت الدراسة الحالية دقة مثالية بلغت 1.00، بينما القيم المقابلة في الدراسات السابقة غير متوفرة. مؤشر Dice ومؤشر Jaccard كانا أيضاً مرتفعين في الدراسة الحالية، حيث بلغا 0.966 و0.934 على التوالي، وهو أفضل من القيم في دراسة 2022، مع غياب القيم المقارنة من دراسة 2019. بالنسبة لنسبة الضغط، تراوحت بين 49% و50% في الدراسة الحالية، دون أي معلومات من الدراسات السابقة، بينما أظهرت الدراسة الحالية سرعة في التنفيذ تتراوح بين 5 و11 ثانية، مع غياب معلومات وقت التنفيذ للدراسات الأخرى. يتضح من الجدول أن الدراسة الحالية توفر أداءً محسناً مقارنة بالدراسات السابقة في معظم المعايير.

الشكل (5) يوضح مقارنة بين عدة مقاييس (Accuracy, Sensitivity, F-score, Precision, Dice, Jaccard) عبر ثلاث دراسات: الدراسة الحالية، دراسة 2022، ودراسة 2019. تمثل الأشرطة القيم لكل مقياس، مع عرض النسب المئوية فوق الأشرطة لتوضيح القيم بدقة. الدراسة الحالية تظهر أداءً أفضل في معظم المقاييس مقارنة بالدراسات السابقة، خاصة في Precision حيث وصلت إلى 100%. الدراسة الحالية أيضاً تتفوق في F-score وDice بنسبة 96.6%. بشكل عام، الدراسة الحالية تظهر تحسناً ملحوظاً في الأداء مقارنة بالدراسات السابقة.

الصور وضغطها، مما أدى إلى دقة تصل إلى 94%، وحساسية بلغت 96.77%، ونوعية 92.23%، مع قيم Precision مثالية (1.0). كما أظهرت الدراسة أداءً عاليًا لضغط الصور مع نسبة ضغط تتراوح بين 45% إلى 50%، بالإضافة إلى تحسين كبير في سرعة التنفيذ، حيث انخفض الزمن اللازم لبعض العمليات إلى 6.27 ثانية.

هذه التحسينات تجعل النظام الحالي أكثر كفاءة ودقة في التشخيص مقارنة بالدراسة السابقة، مما يعزز من فعاليته في التطبيقات الطبية.

التوصيات

1. توسيع قاعدة البيانات: ينصح بجمع وتحليل مجموعات بيانات أكبر وأكثر تنوعًا لتحسين شمولية النموذج وتعزيز دقته.
2. دمج تقنيات إضافية: يمكن استخدام تقنيات تعلم عميق متقدمة مثل الشبكات الالتفافية العميقة (CNN) لتحسين دقة تحليل الصور.
3. تطبيق عملي واسع النطاق: يُوصى بتطبيق النظام في بيئات طبية حقيقية لتقييم أدائه بشكل أكبر وتحديد التحديات المحتملة.
4. تحسين كفاءة الوقت: على الرغم من الأداء الجيد، يمكن تحسين وقت تنفيذ النظام باستخدام تقنيات تحسين أكثر تطورًا.
5. تعزيز قابلية التفسير: يُفضل تطوير واجهات تفسيرية توضح للأطباء سبب التصنيفات التي يقدمها النظام، مما يزيد من ثقتهم باستخدامه.

Author Contributions: "All authors have made a substantial, direct, and intellectual contribution to the work and approved it for publication."

Funding: "This research received no external funding."

Data Availability Statement: "The data are available at request."

Conflicts of Interest: "The author declares no conflict of interest."

References

- [1] J. Clark, F. Brancati, and A. Diehl, "Nonalcoholic fatty liver disease," *Gastroenterology*, 122(6): 1649–1657, 2002.
- [2] S. Rhyou and J. Yoo, "Cascaded deep learning neural network for automated liver steatosis diagnosis using ultrasound images," *Sensors*, 21(16): 5304, 2021.
- [3] S. Mousavi, et al. "Fatty liver level recognition using particle swarm optimization (PSO) image segmentation and analysis," *2022 12th International Conference on Computer and Knowledge Engineering (ICCKE)*, 237–245, 2022.
- [4] M. Owjimehr, H. Danyali, and M. S. Helfroush, "An improved method for liver diseases detection by ultrasound image analysis," *Journal of Medical Signals and Sensors*, 5(1): 21, 2015.
- [5] M. Karagoz, et al, "An unsupervised transfer learning model based on convolutional autoencoder for non-alcoholic steatohepatitis activity scoring and fibrosis staging of liver histopathological images," *Neural Computing and Applications*, 35(14): 10605–10619, 2023.
- [6] X. Guo, et al, "Liver steatosis segmentation with deep learning methods," *2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019)*, 2019.
- [7] A. Akritas and G. Malaschonok, "Applications of singular-value decomposition (SVD)," *Mathematics and Computers in Simulation*, 67(1–2): 15–31, 2004.
- [8] J. Kennedy and R. Eberhart, "Particle swarm optimization," *Proceedings of the IEEE International Conference on Neural Networks*, 1942–1947, 1995.
- [9] Y. Shi, "Particle swarm optimization: developments, applications and resources," *Proceedings of the 2001*

عالية بين الحالات المصابة والسليلة يشير ارتفاع معدل الكشف الإيجابي (TPR) وانخفاض معدل الإيجابية الخاطئة (FPR) إلى كفاءة النموذج في التصنيف، مما يعزز من فعالية هذه التقنيات في دعم عملية التشخيص الطبي، خاصة في ظل غياب الأخصائيين المتخصصين في ليبيا.

المناقشة

أظهرت نتائج الدراسة فعالية النموذج المقترح للكشف عن الكبد الدهني باستخدام التعلم العميق المعزز بخوارزمية تحسين سرب الجسيمات (PSO) من خلال تحليل الصور المضغوطة باستخدام تقنية تحليل القيمة المفردة (SVD)، تمكن النموذج من تحقيق دقة عالية بلغت 94.81%، مما يعكس تقدمًا ملحوظًا مقارنة بالدراسات السابقة التي حققت دقة تقارب 92.2%. أظهر التكامل بين خوارزمية PSO وشبكة التفسير التلقائي (Auto-Encoder) قدرة واضحة على تحسين إعدادات الشبكة، مما ساهم في استخراج ميزات دقيقة وذات صلة بالتشخيص. كما أظهرت مقاييس الأداء الأخرى، مثل F-Score بنسبة 97.34% ومعامل Jaccard بنسبة 94.81%، كفاءة النموذج في تقديم تنبؤات دقيقة وتقليل الأخطاء.

وقد أثبتت خوارزمية PSO فعاليتها في تحسين دقة النموذج وتقليل حجم البيانات بنسبة 45%، مما يدعم استخدام هذه التقنية في التطبيقات الطبية حيث يكون تقليل حجم البيانات مع الحفاظ على الجودة أمرًا ضروريًا. يشير الانخفاض الثابت في RMSE إلى فعالية التكرارات المستمرة لتحسين الأداء، مما يعزز الثقة في استخدام النموذج على نطاق واسع.

الاستنتاجات

1. أداء عالي للتعلم العميق المدعوم بـ PSO: أظهر النظام كفاءة عالية في تصنيف الحالات الطبية بدقة تصل إلى 0.93 لبعض الحالات، مما يثبت فعالية الطريقة المقترحة.
2. دقة وموثوقية في التشخيص: سجلت المؤشرات مثل Jaccard و Dice و Precision قيمًا مرتفعة، مما يعكس موثوقية النموذج في اكتشاف التغيرات المرضية.
3. تحسين ضغط الصور الطبية: حقق النظام نسب ضغط جيدة (45-50%) مع الحفاظ على جودة الصور، مما يسهل تخزين ونقل البيانات جودة الصور المضغوطة. حققت الصور المضغوطة باستخدام SVD جودة بصرية عالية بمؤشر التشابه البنيوي (SSIM) بلغ 1.0 في معظم الحالات.
4. توفير أداة مساعدة للأطباء: قلل النظام من التحديات المرتبطة بالتشخيص اليدوي، مما يعزز من دقة التشخيص الطبي.
5. سرعة التنفيذ: بلغ زمن تنفيذ النموذج حوالي 6.27 ثانية في بعض الحالات، مما يعكس كفاءة استخدام الموارد.
6. يعتمد النظام المقترح في الدراسة الحالية على دمج كل من خوارزمية تحسين السرب الجسيمات (PSO) وتقنيات التعلم العميق (Auto-Encoder)، مما يعزز الأداء مقارنة بالدراسة السابقة. في الدراسة السابقة [3]، استخدم النظام PSO لتقسيم الصور وتحليلها، محققًا دقة بلغت 92.2%، وحساسية 96.77%، ونوعية 92.23%، مع نسبة كشف تصل إلى 95.65%. كما استخدمت مقاييس مثل F-Score و Jaccard، التي بلغت 0.872 و 0.907 على التوالي. أما الدراسة الحالية، فقد أضافت تحسينات من خلال استخدام تقنيات مثل تحليل القيمة المفردة (SVD) لتحسين جودة

- learning in digital mammogram," *IEEE Access*, 9: 55322–55328, 2022.
- [18] A. Thiruneelakandan, et al, "A novel fuzzy c-means based chameleon swarm algorithm for segmentation and progressive neural architecture search for plant disease classification," *ICT Express*, 7(4): 100589, 2021.
- [19] W. Zhang, et al, "Research on segmentation and classification of heart sound signals based on deep learning," *Applied Sciences*, 2022.
- [20] P. Talavera-Martínez, P. Bibiloni, and M. González-Hidalgo, "Hair segmentation and removal in dermoscopic images using deep learning," *IEEE Access*, 9: 2694–2704, 2022.
- [21] A. Umamageswari, et al, "A novel fuzzy c-means based chameleon swarm algorithm for segmentation and progressive neural architecture search for plant disease classification," *ICT Express*, 2021.
- [22] D. Bhupathi, C. Tan, S. Tirumula, "Liver disease detection using machine learning techniques." *Congress on Evolutionary Computation (IEEE Cat. No. 01TH8546)*, 1: 81–86, 2001.
- [10] H. Bandyopadhyay, "Autoencoders in deep learning: Tutorial & use cases," 2022.
- [11] D. Bank, N. Koenigstein, and R. Giryes, *Autoencoders*, 1–22, 2021.
- [12] H. Hukkelås, et al, "Deepprivacy: A generative adversarial network for face anonymization," 2019.
- [13] Y. Wang, H. Yao, "Auto-encoder based dimensionality reduction," *Neurocomputing*, 184: 232–242, 2016.
- [14] D. Bank, N. Koenigstein, and R. Giryes, *Autoencoders*, 2020.
- [15] D. Wang, et al "Particle swarm optimization algorithm: An overview," *Soft Computing*, 22: 387–408, 2018.
- [16] S. Kunapuli and P. Bhallamudi, "A review of deep learning models for medical diagnosis," *Machine Learning, Big Data, and IoT for Medical Informatics*, 389–404, 2021.
- [17] J. Malebary and A. Hashmi, "Automated breast mass classification system using deep learning and ensemble