



المجلة العراقية للعلوم الاقتصادية
Iraqi Journal For
Economic Sciences



PISSN : 1812-8742

EISSE : 2791-092X

Arcif : 0.375

Design and Evaluation of a Hybrid Model Combining Neural Networks and Decision Trees for the Classification of Atopic Dermatitis

تصميم وتقييم نموذج هجين يجمع بين الشبكات العصبية وأشجار القرار في تصنيف التهاب الجلد التأتبي

أ.د. هيفاء طه عبد

Haifa Taha Abd

haefaa_adm@uomustansiriyah.edu.iq

احمد ستار جبار

Ahmed Sattar Jabbar

me4022002@uomustansiriyah.edu.iq

كلية الإدارة والاقتصاد / جامعة المستنصرية

Abstract

Atopic dermatitis is a chronic skin disorder characterized by recurrent inflammation and clinical features that often resemble those of other dermatological diseases, which makes accurate diagnosis challenging. This study aims to investigate the use of digital skin image analysis as a supportive approach for classifying atopic dermatitis through the development of a classification model and its comparison with an alternative method based on a different feature-processing strategy. The study was conducted using a dataset consisting of 1,169 digital images of skin lesions, which were employed for training and evaluation purposes. A hybrid approach combining visual feature extraction with a decision tree-based classification method was developed and compared with a model based on retraining the feature extraction structure. The results demonstrated that the retrained model achieved superior performance, with a classification accuracy of 92.70%, compared to 86.89% for the hybrid model. Further evaluation showed that the proposed approach achieved a balanced performance in terms of sensitivity and specificity, along with a high area under the receiver operating characteristic curve (AUC = 0.9760), indicating reliable and consistent classification outcomes. The findings suggest that image-based analytical models utilizing retraining strategies can effectively enhance the accuracy of atopic dermatitis classification and provide valuable support for clinical decision-making, without replacing direct medical assessment.

Keywords: Atopic Dermatitis, Convolutional Neural Networks, Decision Tree, ResNet-50, Medical Image Processing, Hybrid Model.

المستخلص

يُعد التهاب الجلد التأتبي من الأمراض الجلدية المزمنة التي تتطلب تشخيصاً دقيقاً بسبب تشابه أعراضه مع أمراض جلدية أخرى. يهدف هذا البحث إلى دراسة إمكانية توظيف تحليل الصور الجلدية لدعم تصنيف هذا

المرض من خلال بناء نموذج تصنيفي ومقارنة أدائه مع نموذج بديل يعتمد على أسلوب مختلف في معالجة الخصائص المستخرجة من الصور. اعتمدت الدراسة على مجموعة بيانات تضم (1169) صورة رقمية لآفات جلدية، جرى استخدامها لأغراض التدريب والتقييم. تم اقتراح نموذج هجين يجمع بين استخلاص الخصائص البصرية ونموذج قائم على أشجار القرار، ومقارنته مع نموذج يعتمد على إعادة تدريب البنية المستخدمة في استخلاص الخصائص. أظهرت النتائج تفوق النموذج المعاد تدريبه بدقة بلغت (92.70%) مقارنة بالنموذج الهجين الذي حقق دقة مقدارها (86.89%). كما بينت مؤشرات الأداء الإحصائية أن النموذج المتكامل حقق توازناً جيداً بين الحساسية والنوعية، وسجل قيمة مرتفعة لمساحة ما تحت منحنى الاستقبال التشغيلي (AUC = 0.9760)، مما يعكس استقرار الأداء وتقليل أخطاء التصنيف. وتخلص الدراسة إلى أن نماذج تحليل الصور المعتمدة على إعادة التدريب يمكن أن تساهم في تحسين دقة تصنيف التهاب الجلد التأتبي، وتوفر أداة داعمة لاتخاذ القرار التشخيصي دون أن تحل محل التقييم السريري المباشر.

الكلمات الرئيسية: التهاب الجلد التأتبي، شبكات عصبية تلافيفية، شجرة القرار، (ResNet)-50، معالجة الصور الطبية، النموذج الهجين.

المقدمة

يعدّ التهاب الجلد التأتبي من الأمراض الجلدية المزمنة واسعة الانتشار، ويتميّز بطبيعته الانتكاسية وتداخل أعراضه السريرية مع العديد من الاضطرابات الجلدية الأخرى، مما يجعل تشخيصه الدقيق أمرًا غير يسير في كثير من الحالات. ويعتمد التشخيص في الممارسة السريرية بشكل أساسي على الفحص السريري والخبرة الطبية، وهو ما قد يؤدي إلى تفاوت في دقة التقييم، خاصة في المراحل المبكرة من المرض أو في الحالات ذات المظاهر غير النمطية. وقد تناولت عدة دراسات حديثة كيفية تحسين دقة تشخيص التهاب الجلد التأتبي من خلال الاستفادة من تحليل الصور الجلدية. ففي دراسة أجراها Smith وآخرون [Smith 2022]، تم تحليل الخصائص الشكلية للآفات الجلدية بهدف التمييز بين التهاب الجلد التأتبي وأمراض جلدية التهابية أخرى. وتوصلت الدراسة إلى أن الاعتماد على مجموعة منظمة من الخصائص البصرية يمكن أن يساهم في تحسين دقة التصنيف، إلا أن النتائج ظلت متفاوتة تبعًا لاختلاف جودة الصور وتنوع الحالات السريرية. وفي دراسة أخرى، بحث Johnson و Johnson [Lee 2022] إمكانية استخدام مجموعة من المؤشرات المستخرجة من الصور الجلدية، مثل توزيع الألوان وخصائص النسيج، لدعم عملية التصنيف بين الأنماط المرضية المختلفة. وأظهرت نتائجهم أن دمج أكثر من خاصية تحليلية يحقق أداءً أفضل مقارنة بالاعتماد على مؤشر واحد فقط، كما أشاروا إلى أهمية وضوح آلية التصنيف لضمان إمكانية الاعتماد عليها في البيئات السريرية. أما دراسة Martinez وآخرون [Martinez 2024] فقد ركزت على تطوير أسلوب تصنيفي يوازن بين دقة النتائج وقابلية التفسير، حيث سعت إلى ربط نتائج التصنيف بخصائص مرئية واضحة يمكن للطبيب تتبعها وفهمها. وأكدت الدراسة أن هذا النوع من النماذج يساهم في تعزيز ثقة الأطباء بالنتائج، بشرط استخدامه كأداة مساندة لا كبديل عن الفحص السريري المباشر. دراسة Rasheed et al [2022] ركزت على نموذج هجين يجمع بين الشبكات العميقة وأشجار القرار لتحسين الدقة وتقليل الأخطاء في تصنيف الصور السريرية. [2021] Park et al. قاموا بتحليل صور ثلاثية الأبعاد للإكزما باستخدام أساليب تعلم نماذج الصور، مؤكدين أهمية الدمج بين تمثيل الميزات ودقة التفسير. انطلاقًا من هذه الدراسات، يهدف هذا البحث إلى تصميم وتقييم نموذج تصنيفي يعتمد على دمج أسلوبين مختلفين في معالجة بيانات الصور الجلدية، بما يحقق توازنًا بين القدرة على تمثيل الخصائص البصرية ودقة اتخاذ القرار. ويسعى هذا النهج إلى دعم عملية تشخيص التهاب الجلد التأتبي وتحسين موثوقيتها، مع التأكيد على أن الدور الأساسي يظل للتقييم السريري المباشر من قبل الطبيب المختص.

1. منهجية البحث

أولاً: مشكلة البحث: يُعدّ التهاب الجلد التأتبي من الأمراض الجلدية المزمنة الشائعة، ويصعب تشخيصه بدقة بسبب تشابه أعراضه مع أمراض جلدية أخرى، مثل الصدفية أو التهابات الجلد التحسسية. في الممارسة السريرية، يعتمد التشخيص بشكل أساسي على خبرة الطبيب والفحص البصري، ما يؤدي أحياناً إلى تفاوت في دقة التقييم، خاصة في المراحل المبكرة أو في الحالات التي تظهر فيها الأعراض بشكل غير واضح. هذا التفاوت يخلق حاجة ملحة لتطوير أدوات مساندة يمكن أن تساعد الأطباء في تقييم الصور الجلدية بطريقة أكثر موضوعية وموثوقة.

ثانياً: هدف الدراسة: تهدف هذه الدراسة إلى تصميم وتقييم نموذج تصنيفي يعتمد على تحليل الصور الجلدية لدعم تشخيص التهاب الجلد التأتبي. يسعى النموذج إلى الجمع بين القدرة على تمثيل الخصائص البصرية للآفات الجلدية وبين وضوح آلية اتخاذ القرار، بحيث يكون أداة مساندة للطبيب تساعد على تحسين دقة التشخيص وتقليل الأخطاء، مع التأكيد على أن الدور الأساسي يبقى للتقييم السريري المباشر. وبذلك، تقدم الدراسة مساهمة عملية لفهم كيفية تحسين دعم القرارات الطبية في حالات التهاب الجلد التأتبي باستخدام أساليب تحليل الصور بشكل مبسط ومفهوم.

ثالثاً: أهمية البحث: تنبع أهمية البحث من الحاجة الماسة لتطوير أدوات مساندة للأطباء تساهم في تقليل الأخطاء التشخيصية، خاصة في الحالات التي تتشابه فيها الأعراض. كما يكتسب البحث أهمية علمية من خلال تقديمه دراسة مقارنة بين "نموذج الصندوق الأسود" (الشبكات العصبية) والنموذج القابل للتفسير (شجرة القرار)، مما يساهم في تعزيز الثقة بالأنظمة الذكية في المجال الطبي.

رابعاً: مجتمع وعينة البحث: اعتمد البحث على "مجموعة بيانات صور الأمراض الجلدية" (Skin Diseases Image Dataset) المستمدة من مستودع البيانات العالمي (Kaggle). تكونت العينة من 1,169 صورة سريرية، تم تقسيمها إلى فئتين رئيسيتين:

- 1- فئة إكزما اليدين والقدمين والتهاب الجلد التلامسي (624 صورة).
- 2- فئة الإكزما المزمنة والركودية (545 صورة).

خامساً: منهج البحث: اعتمد البحث المنهج التجريبي المقارن. تم تصميم تجربتين للمقارنة:

- 1- المنهجية الأولى: استخدام شبكة عصبية تلافيفية (ResNet-50) وتدريبها بالكامل.
- 2- المنهجية الثانية: تصميم نموذج هجين يستخدم (ResNet-50) لاستخراج الميزات فقط، وشجرة القرار (Decision Tree) للتصنيف.

سادساً: الإطار الزمني والمكاني: الإطار الزمني: تم إنجاز البحث في قسم الإحصاء، كلية الإدارة والاقتصاد، الجامعة المستنصرية. الإطار المكاني: الفصل الدراسي الثاني للعام 2025-2026.

سابعاً: الاستعراض المرجعي: ركز [Wu et al (2020)] على دراسة تطوير نظام تشخيص آلي للأمراض الجلدية الالتهابية (AIDDA) باستخدام خوارزميات التعلم العميق. اعتمد الباحثون على معمارية EfficientNet-b4 لتدريب النموذج على قاعدة بيانات تحتوي على 4,740 صورة سريرية. وقد شملت الدراسة تصنيف الأمراض إلى فئات رئيسية منها الصدفية (Psoriasis) ومجموعة الأكزيما والتهاب الجلد التأتبي (Eczema & AD). أظهرت النتائج قدرة عالية للنظام المقترح، حيث حقق دقة تشخيص عامة بلغت 95.80%. وفيما يخص فئة الأكزيما والتهاب الجلد التأتبي تحديداً، سجل النموذج دقة بلغت 92.57%، مع حساسية (Sensitivity) بنسبة 94.56% ونوعية (Specificity) بنسبة 94.41%. كما استخدمت الدراسة تقنية t-SNE لتصوير التجمعات

تصميم وتقييم نموذج هجين يجمع بين الشبكات العصبية وأشجار القرار في تصنيف التهاب الجلد التأتبي

العنقودية (Clusters) للفئات المختلفة، مما أثبت قدرة الشبكات العميقة على فصل الخصائص البصرية للأمراض المتشابهة. هدف (Park et al 2021) إلى دراسة إجراء تحليل مقارن شامل بين ثلاثة نماذج للتعليم الآلي: الغابة العشوائية (Random Forest)، وآلة المتجهات الداعمة (SVM)، والشبكات العصبية التلافيفية (CNN)، وذلك لتصنيف التهاب الجلد التأتبي (Atopic Dermatitis) باستخدام صور الميزوسكوب الضوئي الصوتي (RSOM). ركزت الدراسة على التمييز بين الحالات السليمة والمصابين، بالإضافة إلى تصنيف فرعي لشدة المرض. أظهرت النتائج تفوقاً واضحاً لنماذج التعلم العميق، حيث نجح نموذج CNN في التمييز بين الأصحاء والمصابين بدقة بلغت 97%. في المقابل، سجلت الطرق التقليدية مثل Random Forest دقة أقل بلغت 65% عند محاولة تصنيف شدة المرض (Mild vs Moderate-Severe)، وعزت الدراسة ذلك لمحدودية البيانات المتاحة لهذه الفئات الفرعية. اقترحت [Rasheed et al(2022)] نموذجاً هجيناً لتصنيف الأكزيما، ليس فقط كمرحلتين، بل إلى 7 فئات سريرية مختلفة (مثل Atopic, Nummular, Dyshidrotic وغيرها). تميزت هذه الدراسة بإنشاء مجموعة بيانات جديدة أطلقت عليها اسم (EIR) تحتوي على 2039 صورة. ومن الناحية المنهجية، لم يكتفِ الباحثون بالشبكات العميقة، بل قاموا بدمج "الخصائص العميقة مع الخصائص اليدوية، واستخدموا خوارزمية (Relief) الإحصائية لاختيار أهم الخصائص وتحسينها، ثم التصنيف باستخدام آلة المتجهات الداعمة (SVM). حقق النموذج الهجين المقترح دقة كلية بلغت 88.29%، وحساسية 85.19%، ونوعية 90.33%، مما يشير إلى أن دمج الطرق الإحصائية مع التعلم العميق يمكن أن يرفع من كفاءة التشخيص. تناولت [Amina (2025)] دراسة استخدام نماذج التعلم العميق لتصنيف مرض الأكزيما، حيث هدفت إلى تجاوز الطرق التقليدية في تعلم الآلة التي تتطلب تدخلاً يدوياً لاستخراج الخصائص. اعتمدت الباحثة على الشبكات العصبية التلافيفية لتدريب نموذج باستخدام مجموعة بيانات مخصصة لصور الأكزيما تحتوي على فئتين متميزتين وقد أظهرت النتائج تفوق النموذج المقترح حيث حقق دقة تصنيف بلغت (97%)، مما يثبت فعالية الذكاء الاصطناعي في تحسين دقة التشخيص الجلدي مقارنة بالطرق التقليدية. هدفت دراسة [Sari & Keser 2025] إلى تصنيف ثلاثة أمراض جلدية متشابهة بصرياً وهي: الأكزيما (Eczema)، والتهاب الجلد الدهني (Seborrheic Dermatitis)، وسرطان الجلد (Skin Cancer). اقترحت الباحثان منهجية هجينة تعتمد على دمج الشبكات العصبية مع تقنيات اختيار الخصائص الإحصائية، اعتمدت المنهجية على استخدام شبكة (AlexNet) لاستخراج الخصائص (Feature Extraction) من مجموعة بيانات شملت 693 صورة للأكزيما، و750 لسرطان الجلد، و770 للتهاب الجلد الدهني. ولتحسين الأداء الإحصائي، تم استخدام خوارزمية (Relief) اختيار أهم الخصائص المؤثرة وتقليل الأبعاد، ثم تمرير هذه الخصائص إلى مصنف آلة المتجهات الداعمة (SVM) أظهرت النتائج أن دمج خوارزمية (Relief) مع (SVM) رفع دقة التصنيف إلى 92.10%، مقارنة بـ 89.39% عند استخدام شبكة (AlexNet) وحدها، مما يؤكد أهمية المعالجة الإحصائية المسبقة للبيانات في تحسين أداء نماذج التعلم العميق.

المحور الأول: الجانب النظري

يتناول هذا المحور الأسس النظرية للخوارزميات المستخدمة في البحث، حيث يعتمد النظام المقترح على دمج تقنيات التعلم العميق مع خوارزميات التعلم الآلي التقليدية.

أولاً: الشبكات العصبية التلافيفية: تُعد الشبكات العصبية التلافيفية فئة متخصصة من الشبكات العصبية العميقة المصممة لمعالجة البيانات ذات الهيكلية الشبكية مثل الصور. تختلف CNN عن الشبكات التقليدية باستبدالها الضرب المصفوفي الكامل بعملية الالتفاف (Convolution)، مما يمكنها من استخلاص الخصائص المكانية من الصورة بكفاءة عالية.

تصميم وتقييم نموذج هجين يجمع بين الشبكات العصبية وأشجار القرار في تصنيف التهاب الجلد التأتبي


1-عملية الرياضية للالتفاف: 1,10، تتم عملية الالتفاف عبر تمرير مصفوفة (Filter) على الصورة المدخلة لإنتاج خريطة الميزات (Feature Map). رياضياً، إذا افترضنا أن الصورة او الفلتر K، فإن معادلة الالتفاف ثنائي الأبعاد [Wu.et al 2020][Amina 2025]

$$((S(i,j)=(I*k)(i,j)=\sum_m \sum_n I(m,n)K(i-m,j-n)$$

حيث ان: (S(i,j) هي القيمة الناتجة في خريطة الميزات.

I هي صورة ثنائية الأبعاد أو مصفوفة إشارات.
K هي فلتر (kernel) أو مصفوفة صغيرة لتطبيقها على الصورة.
الرمز * هنا يشير إلى convolution الالتفاف.


شكل (1): آلية عمل طبقة الالتفاف، حيث يتم ضرب قيم المصفوفة بجزء من الصورة لإنتاج خريطة الميزات.



2- دوال التنشيط: تُستخدم لإضفاء اللاخطية على الشبكة. تم استخدام دالة الوحدة الخطية

المصححة (ReLU) في الطبقات المخفية لتسريع التدريب وفق الصيغة: [Amina 2025]
وفي طبقة الإخراج، استُخدمت دالة (Softmax) لتحويل المخرجات إلى احتمالات
شرطية للتصنيف $f(x)=(0,x$
 $(\sigma(z)_i=e^{(z_i)} / (\sum_{j=1}^k e^{(z_j)})$)

ثانياً: خوارزمية الشبكات المتبقية ResNet-50: تعالج هذه المعمارية مشكلة تلاشي التدرج (Vanishing Gradient) في الشبكات العميقة من خلال الكتلة المتبقية (Residual Block). تسمح هذه الكتلة للإشارة بالمرور مباشرة عبر وصلة تخطي (Skip Connection). وبدلاً من تعلم الدالة الأصلية (Hx)، تتعلم الشبكة دالة البواقي (Fx)، وتكون المعادلة الحاكمة للكتلة هي: $y=F(x, \{W_i\})+z$ حيث x هي المدخلات و y هي المخرجات. [He et al 2016]
شكل (2) : مخطط الكتلة المتبقية (Residual Block)



يوضح الشكل (2-3) مسار الوصلة المختصرة (Skip Connection) التي تسمح بتدفق التدرج.

1- أشجار القرار: تعتمد الدراسة على خوارزمية (CART) لبناء شجرة القرار. ولضمان أفضل فصل بين الفئات تستخدم الخوارزمية مقياس مؤشر جيني (Gini Impurity) كمعيار للتقسيم في كل عقدة، ويحسب وفق المعادلة التالية:
 $Gini(t) = 1 - \sum_{i=1}^G (p(t))^2$ حيث G: عدد الفئات في المتغير التابع. p(t) : نسبة العينات التي تنتمي للفئة i داخل العقدة t. وتسعى الخوارزمية لاختيار التقسيم الذي يعظم (Gain)، وهو الفرق بين عدم النقاء قبل التقسيم وبعده [Kira and Rendell 1992].

2- التحكم في فرط التخصص: من المعروف إحصائياً أن أشجار القرار تميل إلى (فرط

التخصيص (Overfitting) إذا سمح لها بالنمو بلا حدود، حيث تقوم بحفظ الضجيج (Noise) في بيانات التدريب. ولمعالجة ذلك في هذا البحث، يتم استخدام تقنيات التحديد المسبق (Pre-pruning) مثل تحديد الحد الأقصى- لعمق الشجرة (Max Depth) أو الحد الأدنى لعدد العينات في الورقة، لضمان قدرة النموذج على التعميم (Generalization) عند اختباره على صور طبية جديدة.

ثالثاً: مقاييس تقييم الأداء: لضمان الموثوقية الطبية للنماذج المقترحة، لا يكفي الاعتماد على الدقة العامة فقط. لذا، تم اعتماد مجموعة شاملة من المقاييس الإحصائية لتقييم كفاءة التصنيف من جوانب مختلفة، بالإضافة إلى قياس الكفاءة الحاسوبية (F1_Score).

1- مصفوفة الارتباك: تعتبر مصفوفة الارتباك حجر الزاوية لحساب معظم مقاييس الأداء، وهي عبارة عن جدول رياضي يقارن بين التنبؤات التي أصدرها النموذج والقيم الحقيقية للبيانات. [Sari and Keser, 2025][Rasheed et al 2016] تتكون المصفوفة من العناصر التالية: الإيجابية الصحيحة (True Positive - TP): عدد الحالات المصابة (مثلاً: أكزيما حادة) التي صنفتها النموذج بشكل صحيح.

السلبية الصحيحة (True Negative - TN): عدد الحالات غير المصابة (أو النوع الآخر: أكزيما مزمنة) التي صنفتها النموذج بشكل صحيح.

الإيجابية الخاطئة (False Positive - FP): (خطأ من النوع الأول Type I Error): حالات صنفتها النموذج على أنها حادة وهي في الواقع مزمنة.

السلبية الخاطئة (False Negative - FN): (خطأ من النوع الثاني Type II Error): حالات صنفتها النموذج على أنها مزمنة وهي في الواقع حادة.

رابعاً: المقاييس الإحصائية المشتقة: بناءً على مصفوفة الإرباك، يتم حساب المقاييس التالية:

1- الدقة الكلية: [Wu et al, 2020](Accuracy) هي نسبة التوقعات الصحيحة كلياً (سواء كانت إيجابية أو سلبية) إلى إجمالي عدد العينات

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

2- الدقة الإيجابية: تقيس دقة النموذج عندما يتنبأ بوجود الحالة الإيجابية. بمعنى آخر من بين

كل الصور التي قال النموذج أنها أكزيما حادة، كم واحدة كانت حادة فعلاً؟ $Precision = \frac{TP}{TP+FP}$

3- الاستدعاء أو الحساسية: يُعد هذا المقياس الأهم في المجال الطبي، حيث يقيس قدرة النموذج على اكتشاف جميع الحالات المصابة وعدم تفويتها. بمعنى آخر من بين جميع حالات

الأكزيما الحادة الموجودة فعلياً، كم واحدة استطاع النموذج اكتشافها؟ $Recall = \frac{TP}{TP+FN}$

4- مقياس F1-Score: يعد هذا المقياس المتوسط التوافقي (Harmonic Mean) بين الدقة

الإيجابية (Precision) والاستدعاء (Recall). وتكمن أهميته القصوى في الحالات التي يكون فيها توزيع البيانات غير متوازن، أو عندما نسعى لتحقيق توازن بين تقليل الإنذارات الكاذبة (FP)

وعدم تفويت الحالات المرضية (FN). يعطي F1-Score تقيماً أكثر واقعية من الدقة الكلية (Accuracy) في هذه الحالات، ويُحسب وفق المعادلة التالية: [Rasheed et al

$$f1 - Score = 2 * \frac{Precision * Recall}{recision + Recall} [2016]$$

5- منحنى الخصائص التشغيلية للمستقبل ROC Curve: هو تمثيل بياني يوضح قدرة

المصنف الثنائي على التمييز بين الفئات عند عتبات تنشيط (Thresholds) مختلفة. المحور

السييني (X-axis): يمثل معدل الإيجابية الخاطئة [Wu et al, 2029](False Positive Rate)

(FPR) أي. (1 - Specificity) المحور الصادي (Y-axis): يمثل معدل الإيجابية الصحيحة

(True Positive Rate - TPR) أي. (Sensitivity) يتم تقييم المنحنى عبر حساب المساحة

تصميم وتقييم نموذج هجين يجمع بين الشبكات العصبية وأشجار القرار في تصنيف التهاب الجلد التأتبي

تحت المنحنى (AUC - Area Under Curve). كلما اقتربت قيمة AUC من واحد، دل ذلك على أن النموذج مثالي في الفصل بين الفئتين، بينما تشير القيمة 0.5 إلى أن النموذج يتنبأ عشوائياً.

المحور الثاني: الجانب التطبيقي

1. تحليل البيانات: يستعرض هذا القسم المنهجية العلمية والخطوات الإجرائية التي تم اتباعها لتحقيق أهداف الدراسة المتمثلة في تصنيف صور التهاب الجلد التأتبي (Atopic Dermatitis) بدقة وكفاءة. اعتمدت الدراسة في تحليل البيانات على منهجية تجريبية مقارنة بين مسارين أساسيين: المسار الأول (التعلم العميق المتكامل): يعتمد كلياً على تقنيات التعلم العميق (End-to-End Deep Learning) باستخدام هندسة شبكة (ResNet-50). المسار الثاني (النهج الهجين): يقترح نهجاً هجيناً (Hybrid Approach) يدمج بين قدرة الشبكات العصبية التلافيفية على استخراج الميزات العميقة (Deep Feature Extraction) وبين القوة الإحصائية والتفسيرية لخوارزمية شجرة القرار (Decision Tree) في عملية التصنيف.

2. وصف وتجهيز مجموعة البيانات Dataset Acquisition and Preparation:

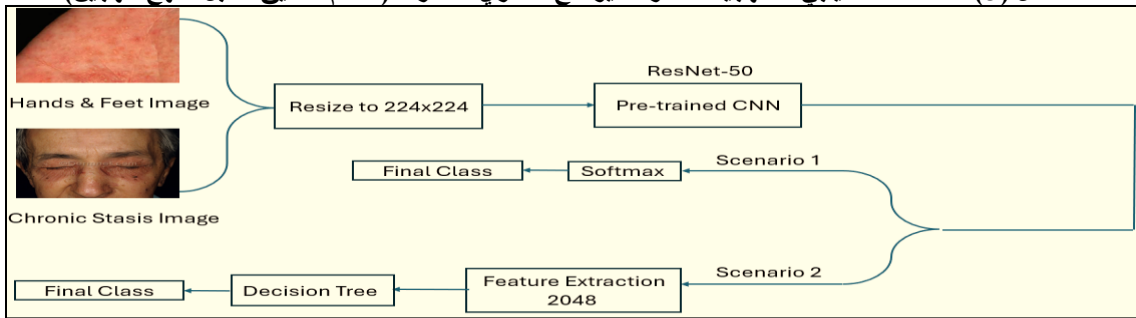
اعتمدت الدراسة في جانبها التطبيقي على مجموعة بيانات صور الأمراض الجلدية (SkinDiseasesImage Dataset) المستمدة من مستودع البيانات العالمي (Kaggle). ركزت الدراسة بشكل دقيق على فئتين فرعيتين للأكزيما والتهاب الجلد، مما يضيف بعداً طبياً دقيقاً لعملية التصنيف. وقد مرت عملية التجهيز بمراحل تقنية لضمان دقة البيانات الإحصائية **الفئة الأولى:** إكزما اليدين والقدمين والتهاب الجلد التلامسي (624 صورة).

الفئة الثانية: الإكزما المزمنة والركودية والدرهمية (545 صورة). تم تقسيم البيانات عشوائياً بنسبة 80% للتدريب و20% للاختبار، مع إجراء عمليات المعالجة الأولية مثل توحيد أحجام الصور إلى (224x224) لتوافق مدخلات الشبكة.

3- تصميم النظام المقترح: تم تطبيق منهجيتين للمقارنة بينهما:

1- المخطط الهيكلي للنظام المقترح: تم تصميم النظام ليعمل وفق مسارين (TwoScenarios) للمقارنة، كما هو موضح في المخطط الانسيابي الشكل (3):

الشكل (3) المخطط الانسيابي للمنهجية المقترحة يوضح مساري المقارنة (التعلم العميق مقابل النهج الهجين)



ب. تنفيذ خوارزمية استخراج الميزات وتجهيز البيانات: تمت برمجة مرحلة استخراج الميزات وتجهيز البيانات في بيئة MATLAB لتعمل بشكل آلي، حيث يقوم النظام بقراءة المجلدات، معالجة الصور، استخراج الخصائص الرقمية عبر شبكة ResNet-50، ثم تقسيم البيانات إحصائياً. وفيما يلي تفصيل لهذه الخطوات البرمجية:

أولاً: تعريف مسارات البيانات والتحميل الآلي لضمان دقة التصنيف، تم تعريف هيكلية البيانات برمجياً باستخدام مصفوفة خلوية تربط مسار كل فئة بالرمز الرقمي الخاص بها (Label).

تصميم وتقييم نموذج هجين يجمع بين الشبكات العصبية وأشجار القرار في تصنيف التهاب الجلد التأتبي

ثانياً: المعالجة قبلية واستخراج الميزات العميقة تتضمن هذه المرحلة تحميل شبكة ResNet-50 بأوزان ImageNet. ونظراً لأن الشبكة تتطلب صوراً ملونة (RGB) بأبعاد محددة، فقد تم تضمين شرط برمجي (repmat) لمعالجة الصور الرمادية (Grayscale) وتحويلها لتوافق مدخلات الشبكة، ومن ثم استخراج الميزات من طبقة avg_pool.

ثالثاً: التقسيم الإحصائي للبيانات (Data Splitting) لضمان نزاهة التقييم، تم استخدام دالة cvpartition لتقسيم البيانات عشوائياً، مع الحفاظ على التوزيع الطبقي للفئات.

4. المنهجية الأولى: نموذج ResNet-50 المتكامل: تعتمد هذه المنهجية على استراتيجية نقل التعلم حيث يتم الاستفادة من شبكة ResNet-50 المدربة مسبقاً على قاعدة بيانات ImageNet الضخمة (التي تحتوي على ملايين الصور وألف فئة مختلفة). بدلاً من بناء الشبكة من الصفر، يتم استخدام الأوزان المسبقة كنقطة انطلاق قوية، ثم يتم إجراء عملية إعادة ضبط دقيق (Fine-Tuning) لتكييف الشبكة مع المهمة المحددة في هذا البحث وهي تصنيف الأكرزما.

5. تعديل معمارية الشبكة: تتكون شبكة ResNet-50 الأصلية في طبقاتها الأخيرة من طبقة متصلة بالكامل (FullyConnectedLayer) بخرج حجمه 1000، وطبقة تصنيف (Classification Layer) لـ 1000 فئة. ولجعل الشبكة متوافقة مع بياناتنا (التي تحتوي على فئتين فقط)، تم إجراء التعديلات الهيكلية التالية برمجياً:

1. حذف الطبقات النهائية: تم إزالة الطبقات الثلاث الأخيرة من الشبكة الأصلية وهي:

(i) Fully Connected Layer (fc1000)

(ii) Softmax Layer (fc1000_softmax)

(iii) Classification Output (ClassificationLayer_fc1000)

2. إضافة طبقات جديدة: تم استبدال الطبقات المحذوفة بطبقات جديدة تتناسب مع عدد فئات البحث (2 Classes)، وهي:

(i) طبقة متصلة بالكامل (New FC Layer): بعدد مخارج يساوي 2 (يتوافق مع الفئتين

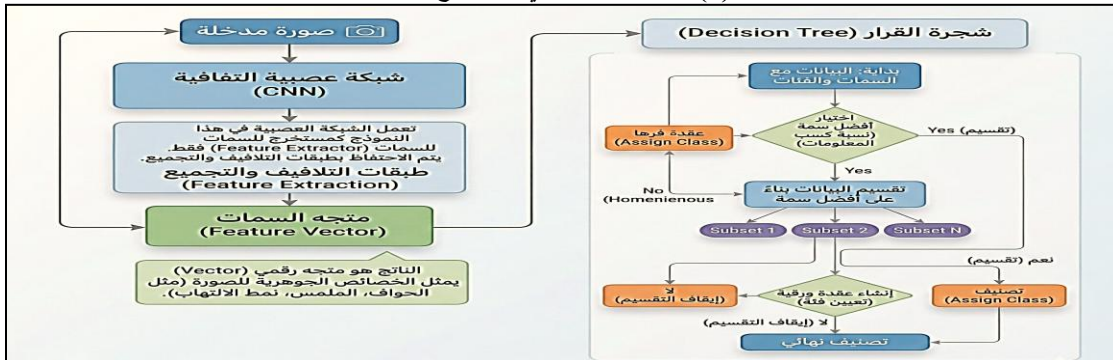
المستهدفتين). تم تعيين معامل تعلم (Weight Learn Rate Factor) بقيمة 10 لتسريع تعلم هذه الطبقة الجديدة مقارنة بباقي الطبقات المجمدة أو البطيئة التعلم.

(ii) طبقة سوفت ماكس (Softmax Layer): لتحويل المخرجات إلى احتمالات..

(iii) طبقة التصنيف (Classification Output Layer): لحساب الخطأ واتخاذ القرار النهائي

6. المنهجية الثانية: النموذج الهجين Hybrid Model: في هذه المنهجية، استُخدمت شبكة ResNet-50 كمستخرج للميزات (Feature Extractor) فقط دون إعادة تدريب. تم استخلاص متجه الخصائص (بطول 2048) من طبقة التجميع المتوسط (Global Average Pooling)، ثم تم تمرير هذه الخصائص لتدريب مصنف شجرة القرار باستخدام معيار مؤشر جيني للفصل بين الفئات، والشكل 4 يوضح المخطط الانسيابي للنموذج الهجين.

شكل (4) المخطط الانسيابي للنموذج الهجين



تصميم وتقييم نموذج هجين يجمع بين الشبكات العصبية وأشجار القرار في تصنيف التهاب الجلد التأتبي

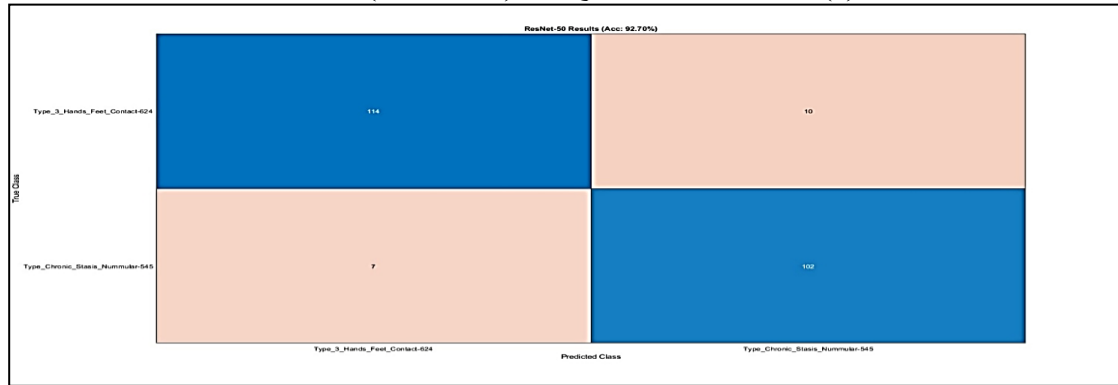
7. عرض النتائج ومناقشتها: يستعرض هذا الفصل نتائج التجارب العملية التي أجريت لتقييم أداء النظام المقترح. تم اعتماد منهجيتين مختلفتين لاستخدام تقنيات التعلم العميق (Deep Learning) والمقارنة بينهما ضمن منهجيتين المنهجية الأولى Fine-Tuning End-to-End : إعادة تدريب شبكة ResNet-50 بالكامل لتصنيف الصور مباشرة. المنهجية الثانية: نموذج هجين يعتمد على استخدام ResNet-50 كمستخرج للخصائص وتميرها إلى مصنف شجرة القرار (Decision Tree). تم تقسيم البيانات في كلتا التجربتين بنسبة 80% للتدريب و20% للاختبار لضمان عدالة المقارنة.

1. نتائج المنهجية الأولى: نموذج ResNet-50 المعدل: في هذه التجربة، تم تدريب الشبكة العصبية لتحديث أوزانها بناءً على بيانات الأكزيما (Fine-Tuning).
أداء التدريب ومصفوفة الارتباك: أظهر النموذج استقراراً سريعاً وتقارباً ممتازاً، وحقق دقة تصنيف عالية جداً.


الشكل (5): مخطط تقدم التدريب لنموذج ResNet-50.



أداء النموذج الأول (ResNet-50): أظهرت النتائج تفوقاً واضحاً لهذا النموذج، حيث حقق دقة تصنيف كلية بلغت 92.70%، وبلغت المساحة تحت المنحنى (AUC=0.9760)، مما يعكس قدرة عالية على التمييز بين أنواع الإكزيما بحساسية ونوعية مرتفعتين.
الشكل (6) مصفوفة الارتباك النموذج الأول (ResNet-50) بدقة 92.70%



الشكل (7): منحنى ROC لنموذج ResNet-50

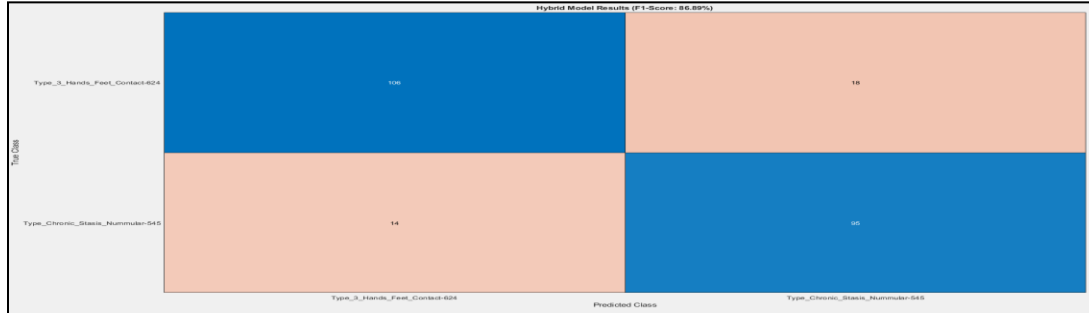


تصميم وتقييم نموذج هجين يجمع بين الشبكات العصبية وأشجار القرار في تصنيف التهاب الجلد التأتبي

ب. أداء النموذج الثاني الهجين: في هذه التجربة، تم تجميد طبقات ResNet-50 واستخدام طبقة التجميع المتوسط لاستخراج متجه خصائص (Feature Vector) لكل صورة، ومن ثم تدريب مصنف شجرة القرار (Decision Tree) بناءً على هذه الخصائص.


مصفوفة الارتباك للنموذج الهجين: يوضح الشكل (4-4) أداء النموذج الهجين. رغم استخدام نفس مستخرج الخصائص (ResNet-50)، إلا أن الاعتماد على مصنف خارجي (Tree) أدى إلى انخفاض طفيف في الأداء مقارنة بالنموذج المتكامل. سجل النموذج الهجين دقة بلغت (86.89%) وقيمة (AUC = 0.8270). وعلى الرغم من أن النتائج مقبولة، إلا أنها أقل كفاءة مقارنة بالنموذج المتكامل، ويرجع ذلك إلى أن شجرة القرار تعتمد على حدود فصل خطية قد لا تكون كافية للتعامل مع التداخل الكبير في خصائص الصور الطبية.

الشكل (8): مصفوفة الارتباك للنموذج الهجين (الدقة: 86.89%).



منحنى ROC للنموذج الهجين :

الشكل (9): منحنى ROC للنموذج الهجين.



بلغت قيمة $AUC = 0.8270$. يشير هذا إلى أن الخصائص المستخرجة كانت جيدة، لكن شجرة القرار لم تستطع الفصل بينها بنفس كفاءة الطبقات المتصلة بالكامل (Fully Connected Layers) الموجودة داخل الشبكة العصبية الأصلية.

8. مقارنة الأداء والمناقشة: يلخص الجدول (1) المقارنة النهائية بين المنهجيتين.

الجدول (1): مقارنة بين النموذج المتكامل (Fine-Tuned) والنموذج الهجين (Hybrid)

المقياس	ResNet-50	Hybrid (ResNet-50 Features + Tree)	الفرق
Accuracy	92.70%	86.89%	5.81%
Precision	94.21%	88.33%	5.88%
Recall	91.94%	85.48%	6.46%
Specificity	93.58%	87.16%	6.42%
F1-Score	93.06%	86.89%	6.17%

مناقشة المقارنة: يُظهر الجدول (1) أن إعادة تدريب الشبكة العصبية (Fine-Tuning) ساهمت في رفع الدقة بمقدار 5.81% وتحسين الحساسية (Recall) بمقدار 6.46% مقارنة بالنهج الهجين. يُعزى ذلك إلى أن الشبكة في المنهجية الأولى تعلمت خصائص دقيقة جداً للمرض (مثل نمط القشور والاحمرار)، بينما اعتمد النموذج الهجين على ميزات عامة للصورة، مما يثبت فعالية التعلم العميق المتكامل في التشخيص الطبي الدقيق.

الاستنتاجات والتوصيات

أولاً: الاستنتاجات

- 1- أثبتت النتائج كفاءة الشبكات العصبية التلافيفية (ResNet-50) في تشخيص التهاب الجلد التأتبي بدقة عالية بلغت 92.70%، مما يجعلها أداة مساندة قوية للأطباء.
- 2- تبين أن إعادة تدريب الشبكة لتحديث أوزانها تعطي نتائج أفضل بفارق 6% تقريباً مقارنة بالنهج الهجين الذي يستخدم الشبكة كمستخرج للميزات فقط، مما يؤكد حاجة النظام لتعلم الخصائص الدقيقة للمرض.
- 3- حقق النموذج المقترح توازناً ممتازاً بين الحساسية والنوعية، وسجل مساحة تحت المنحنى (AUC=0.9760)، مما يدل على استقرار النظام وقلة الإنذارات الكاذبة.
- 4- رغم أن النموذج الهجين (شجرة القرار) حقق نتائج مقبولة (86.89%)، إلا أنه أظهر قصوراً في التعامل مع التداخلات المعقدة بين الفئات مقارنة بالقدرة غير الخطية للشبكات العميقة.

ثانياً: التوصيات

- 1- جمع المزيد من الصور السريرية المتنوعة من مصادر طبية مختلفة لرفع دقة النموذج وتحسين قدرته على التعميم.
- 2- دمج تقنيات الذكاء الاصطناعي القابل للتفسير (مثل Grad-CAM) لتوضيح المناطق التي استند إليها النموذج في التشخيص، مما يعزز ثقة الأطباء في النظام.
- 3- توسيع نطاق النظام ليشمل تصنيف أمراض جلدية أخرى شائعة (كالصدفية وحب الشباب) وعدم الاقتصار على الإكزما فقط.

المصادر References

- 1-Amina, D. E. (2025). Eczema classification using deep learning models. *International Journal of Multidisciplinary Conference Proceedings*, 2(1), 39.
- 2-He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE on Computer Vision and Pattern Recognition* (pp. 770–778).
- 3-Johnson, M. L., & Lee, H. S. (2023). Multivariate image feature integration for dermatological classification. *Clinical Dermatology Studies*, 12(1), 78–91. <https://doi.org/10.1177/20503121231102456>
- 4-Kira, K., & Rendell, L. A. (1992). The feature selection problem: Traditional methods and a new algorithm. *AAAI*, 2, 129–134.
- 5-Martinez, P., Nguyen, T., & O'Connor, D. (2024). Enhancing interpretability in lesion-based classification approaches. *International Journal of Skin Diagnostics*, 7(2), 102–115. <https://doi.org/10.1016/j.ijd.2024.01.008>.
- 6-Park, S., Saw, S. N., Li, X., Paknezhad, M., Coppola, D., Dinish, U. S., & Olivo, M. (2021). Model learning analysis of 3D optoacoustic mesoscopy images for the classification of atopic dermatitis. *Biomedical Optics Express*, 12(6), 3671–3683. <https://doi.org/10.1364/BOE.415105>.
- 7-Rasheed, A., Umar, A. I., Shirazi, S. H., Khan, Z., Nawaz, S., & Shahzad, M. (2022). Automatic eczema classification in clinical images based on hybrid deep neural network. *Computers in Biology and Medicine*, 147, 105807.
- 8-Sarı, M. O., & Keser, K. (2025). Classification of skin diseases with deep learning-based approaches. *Scientific Reports*, 15(1), 27506.
- 9-Smith, J., Brown, A., & Patel, R. (2022). Systematic analysis of lesion morphology in atopic dermatitis and related conditions. *Journal of Dermatological Research*, 58(4), 234–245. <https://doi.org/10.1016/j.jdermres.2022.04.006>.
- 10-Wu, H., Yin, H., Chen, H., Sun, M., Liu, X., Yu, Y., Tang, Y., Long, H., Zhang, B., Zhang, J., Zhou, Y., Li, Y., Zhang, G., Zhang, P., Zhan, Y., Liao, J., Luo, S., Xiao, R., Su, Y., Zhao, J., Wang, F., Zhang, W., Zhang, J., & Lu, Q. (2020). A deep learning, image-based approach for automated diagnosis for inflammatory skin diseases. *Annals of Translational Medicine*, 8(9), Article 581. <https://doi.org/10.21037/atm.2020.04.39>