

## نظام تشخيص سرطان الثدي بمساعدة الحاسب

### باستخدام التعلم العميق

\* أ.د.م. مريم محمد ساعي  
\* \* م. لجين محمد أبو كف

#### ملخص البحث

يعتبر سرطان الثدي أحد أنواع السرطانات المنتشرة بكثرة بين النساء في جميع أنحاء العالم والذي يؤدي إلى موت العديد من النساء كل عام بسبب التشخيص الخاطئ والعلاج المتأخر. لذلك في السنوات الأخيرة بدأ الاعتماد على أنظمة الكشف عن سرطان الثدي بمساعدة الحاسب وذلك بالاعتماد على صور الماموغرام المأخوذة من المريض وقد حققت خوارزميات التعلم العميق والرؤية الحاسوبية نتائج عالية في هذا المجال، حيث أثبتت الشبكات العصبونية الالتفافية كفاءتها من ناحية التعامل مع قواعد البيانات التي تحتوي على صور بأبعاد مكانية كبيرة. تم في هذا البحث تصميم نظام تشخيص سرطان الثدي بمساعدة الحاسب باستخدام قاعدة البيانات mini-mias التي تحتوي على 322 عينة موزعة على ثلاث أصناف (سليمة -ورم حميد-ورم خبيث) و ذلك بالاعتماد على الشبكات العصبونية الالتفافية convolution Neural Network(CNN) وتقنية نقل التعلم. تم المقارنة بين مجموعة من الشبكات المدربة مسبقاً وأعطت شبكة VGG16 الأداء الأفضل ثم تم القيام باستبدال الطبقات كاملة الاتصال وضبط المعاملات العليا للنموذج (عدد وحدات الطبقات كاملة الاتصال الجديدة ومعامل الإسقاط) بالاعتماد على خوارزمية بايز. حقق النموذج دقة 96% و92% و95% للصنف السليم والحميد والخبيث بالتتالي وقيمة Area Under Curve تعادل 98% لكل صنف.

## الكلمات المفتاحية: الشبكات العصبونية الالتفافية-تقنية نقل التعلم-خوارزمية بايز- الماموغرام-أنظمة التشخيص بمساعدة الحاسب-التصنيف المتعدد.

---

\* أستاذ ، قسم هندسة الحاسبات والتحكم الآلي، كلية الهندسة الميكانيكية والكهربائية، جامعة تشرين، اللاذقية، سوريا.  
\*\*طالبة دراسات عليا(ماجستير)، قسم هندسة الحاسبات والتحكم الآلي، كلية الهندسة الميكانيكية والكهربائية، جامعة تشرين،  
اللاذقية ، سوريا.

# Computer-Aided Diagnosis System for Breast Cancer Using Deep Learning

\*Prof.Mariam Saii  
Abokaff

\*\*Lujain

## ABSTRACT

Breast cancer is one of the most common types of cancer among women all over the world, which leads to the death of many women every year due to wrong diagnosis and late treatment. Therefore, in recent years, researchers tend to use computer-aided diagnosis systems in order to help radiologists in detecting the cancer. Deep learning and computer vision algorithms have achieved high results in this field as convolution neural networks have proven their efficiency in terms of dealing with dataset that contain images with large spatial dimensions. In this research, a computer-Aided diagnosis system was built using the mini MIAS dataset, which contains 322 samples distributed into three classes (normal, benign, and malignant) based on convolution neural networks and transfer learning. A comparison of a group of pre-trained networks was made, where the VGG16 gave the best performance. Then a replacement of the fully connected layers and adjusting the hyper parameters of the model (the number of units of the fully connected layers and dropout rate) was done by using Bayesian hyperparameter tuning .Our model achieved 96%, 92%, and 95% accuracy for the normal, benign, and malignant class, respectively and the Area Under curve was 98% for all three classes.

**Keywords:** Convolution Neural Networks, Transfer Learning, Bayesian hyperparameter tuning, Mammogram, CAD, Multiclassification.

---

\*Professor, Department of Computers and Automatic Control, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria.

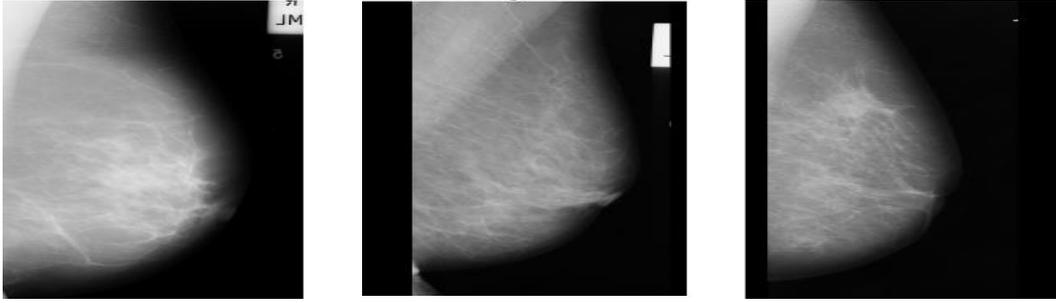
\*\* Master's Student, Department of Computers and Automatic Control, Faculty of Mechanical and Electrical Engineering, Tishreen University, Lattakia, Syria.

## 1-مقدمة

يعد سرطان الثدي أحد الأسباب الرئيسية لوفاة النساء على مستوى العالم. وفقاً لمنظمة الصحة العالمية (WHO) World Health Organization، سيكون عدد حالات السرطان المتوقعة في عام 2025 ما يقارب 19.3 مليون حالة. يعتبر مرض السرطان في سوريا مشكلة صحية عامة وقد أخذ المرض في التزايد بوتيرة سريعة وخاصة سرطان الثدي حيث كشفت وزارة الصحة السورية أن السرطانات الأكثر شيوعاً لدى النساء في سوريا هي سرطان الثدي بنسبة 30%، يليه القولون والدم والمستقيم كما أن 70% من الحالات المصابة تُراجع المؤسسات الصحية بمراحل سريرية متأخرة. [1]

يعد الكشف المبكر عن المرض من خلال اختبارات الفحص مثل التصوير الشعاعي للثدي mammograms طريقة فعالة لإنقاذ حياة المرضى عن طريق تقديم العلاج قبل فوات الأوان حيث يقوم أخصائي الأشعة بتحليل صور الماموغرام و تشخيص السرطان بالاعتماد على وجود الكتل masses بالإضافة إلى التكتلات الدقيقة Microcalcification و تعتبر هذه العملية معقدة وتتطلب خبرة وكفاءة عالية.

لتوضيح تعقيد تفسير صور الماموغرام ، يبين الشكل (1) ثلاثة صور شعاعية مختلفة للثدي تحتوي على حالات طبيعية و غير طبيعية (حميدة وخبيثة) ومدى تشابهها جميعاً بالنسبة للعين غير المدربة.



(A)

(B)

(C)

الشكل(1): صور ماموغرام مأخوذة من قاعدة البيانات mini-mias: (A) حالة سليمة- (B) ورم حميد- (C) ورم خبيث

ولسوء الحظ هناك نقص في أخصائيي الأشعة خاصة في البلدان النامية وبالتالي هذا يمكن أن يؤدي إلى التأخر في التشخيص والعلاج ، كما تلعب العوامل الخارجية مثل الإرهاق والتشتيت عاملاً أساسياً

في دقة التشخيص ، حيث أن معدلات التشخيص الخاطئ بسرطانات الثدي أثناء فحوصات صور الماموغرام الأولية عالية وتقدر بحوالي 30%. تؤدي التفسيرات الخاطئة للمرض من قبل أطباء الأشعة إلى قرارات تضر المرضى حيث أنه عند تشخيص الحالة على أنها ورم خبيث ، فعادة ما يتم وصف الخزعات (استخراج الخلايا من أنسجة الثدي) مما يؤدي إلى إجراءات علاجية غير ضرورية بالإضافة إلى القلق والألم للمرضى ومن ناحية أخرى ، يمكن عدم ملاحظة وجود الورم تمامًا مما يؤدي إلى عدم تقديم العلاج وهذا يشكل خطر على حياة المريض و يسبب الوفاة لذلك كان لا بد من العمل على تطوير طرق جديدة للكشف عن المرض باستخدام التقنيات المختلفة حيث بدأ الباحثون بالاتجاه إلى الاستعانة بتقنيات الذكاء الصناعي في المجال الطبي من أجل بناء أنظمة تشخيص بمساعدة الحاسب فعالة تقدم المساعدة للعنصر البشري وتساعد في تقليل التشخيص الخاطئ وبالتالي التقليل من نسب الوفيات الناتجة عنه. في بداية القرن العشرين تم التوجه إلى تطبيق خوارزميات تعلم الآلة عند التعامل مع قواعد البيانات المجدولة (السجلات الطبية) حيث قامت Aruna [2] باستخدام مصنف نايف بايز naïve Bayes على قاعدة بيانات Breast Cancer Wisconsin Diagnostic Data Set التي تحتوي على 569 عينة (سجل طبي) متضمنة 32 سمة وتم استخلاص السمات يدوياً و الوصول إلى نموذج كشف بدقة 96.48%. وفي عام 2013 استخدمت Dina ragab [3] تحويل الموجات المنقطع Discrete Wavelet Transform (DWT) من أجل استخراج السمات للكشف عن وجود الكتلة في الثدي بالإضافة إلى إجراء المقارنة بين شعاع الدعم الآلي Support vector machine (SVM) والشبكات العصبونية Artificial Neural Network(ANN) للتصنيف بين الحالات الطبيعية ، والأورام الحميدة والخبيثة وكان معدل الكشف المحقق 96% للشبكة العصبونية و 98% بالنسبة لمصنف شعاع الدعم الآلي . وفي السنوات الأخيرة ونظراً للتطور الكبير في العتاد المادي للحاسب وظهور وحدات المعالجة الرسومية بالإضافة إلى حجم البيانات الطبية المتاحة المتزايد أصبح التعلم العميق مجالاً ناشطاً من الذكاء الصناعي حيث يسمح للنماذج التي تتكون من طبقات

معالجة متعددة بتعلم تحليل البيانات مع مستويات متعددة من التجريد واستخراج السمات بشكل آلي وبالتالي بناء نظام تشخيص أسرع وأكثر دقة حيث في عام 2016 استخدم الباحث Daniel Levy [4] نوع من أنواع الشبكات العميقة المدربة مسبقاً AlexNet لتصنيف الكتل الحميدة والخبيثة في تصوير الثدي بالأشعة السينية بالاعتماد على قاعدة بيانات DDSM (Digital Database for Screening Mammography) والتي تحتوي على 2620 صورة ماموغرام حيث تم إعادة تحجيم الصور وفق الحجم المتوقع لطبقة الدخل للشبكة المدربة المسبقة  $3*224*224$  واستخدام تحويلات زيادة البيانات data augmentation من أجل زيادة عدد عينات التدريب ثم الاحتفاظ بالأوزان البدائية للشبكة واستبدال الطبقة الأخيرة بطبقة تحتوي على عصبونين (تصنيف ثنائي) وكانت الدقة المحققة 66% وحقق النموذج قيمة Area Under Curve تعادل 81% وفي عام 2017 استخدمت Teresa Araujo [5] الشبكة العصبونية الالتفافية في مرحلة استخلاص السمات بشكل آلي ثم استخدام مصنف شعاع الدعم الآلي من أجل تصنيف الصور المجهرية ضمن أربع أصناف وقد حقق النموذج دقة 77.8%. لاحقاً قام Arfan Jaffar [6] باستخدام الشبكة العصبونية الالتفافية وتدريبها على قاعدة بيانات Digital Database for Screening Mammography من أجل استخلاص السمات ثم ادخال شعاع السمات إلى مصنف الدعم الآلي من أجل القيام بعملية التصنيف الثنائي للعينات إلى ورم حميد وورم خبيث. حققت نماذج التعلم العميق المدربة مسبقاً أداءً ممتازاً في تحديات تصنيف الصور في مجالات مختلفة بما في ذلك تحليل الصور الطبية وعلى وجه الخصوص في صور التشريح المرضي. وفي عام 2019 استخدم Prabhpeet kaur [7] مجموعة بيانات Mini-MIAS (322 صورة ماموغرام) لبناء نموذج شبكة عصبونية التفافية مع شعاع الدعم الآلي متعدد الأصناف يمكنه تصنيف الفئات السليمة والحميدة والخبيثة حيث تم استخدام الشبكة العصبونية الالتفافية في مرحلة استخلاص السمات ثم ادخال شعاع السمات إلى المصنف و قد حقق النموذج متوسط معدل دقة يصل إلى 94 %، وفي عام 2019 قامت DINA ragab [8] باستخدام طريقتين من أجل استخلاص المنطقة ذات الأهمية Region of

interest(ROI) حيث اعتمدت الطريقة الأولى على اقتطاع المنطقة بالطريقة اليدوية بينما تعتمد الطريقة الثانية على استخدام العتبة Threshold ثم تم ضبط بارامترات شبكة AlexNet وذلك بعد استبدال طبقة التصنيف للشبكة الأصلية بطبقة تحتوي على عصبون واحد من أجل القيام بعملية التصنيف الثنائي وقد حقق النموذج دقة 73.62%. في عام 2020 ، حاول الباحثون استخدام شبكات عميقة جديدة قوية ومُدربة مسبقاً على قواعد بيانات ضخمة وباستخدام عتاد مادي متطور لأن تدريب الشبكة العصبونية الالتفافية العميقة من الصفر غالباً ما يتطلب حجماً كبيراً من بيانات التدريب المصنفة والتي قد لا تكون متاحة بسهولة في المجالات الطبية ، لذلك أصبحت تقنية نقل التعلم transfer learning الحل الأمثل. لاحقاً استخدمت Aditya Khamparia [9] نموذج نقل تعلم معدّل (MVGG16) على مجموعة بيانات Digital Database for Screening Mamography حيث تم المقارنة بين مجموعة من النماذج المدربة مسبقاً (VGG19, MobileNet, ResNet50, MVGG16) و حققت شبكة MVGG16 الأداء الأفضل في مرحلة استخلاص السمات ثم تم القيام بعملية ضبط بارامترات للنموذج حيث تم حذف الطبقة الأخيرة واستبدالها بطبقة تحتوي عصبون واحد ثم تدريب النموذج على قاعدة البيانات وذلك بعد تطبيق التحويلات المختلفة عليه ( دوران -تكبير-قص- قلب شاقولي) وذلك من أجل زيادة تعميم النموذج والحصول على أداء أفضل وتم الوصول إلى دقة تبلغ 88.3% .في وقت لاحق من عام 2020 ، طبق Kadir GUZEL [10] ثلاث طرق مختلفة لضبط بارامترات الشبكة المدربة مسبقاً حيث أن الطريقة الأولى تعتمد على تجميد جميع الطبقات (الاحتفاظ بالأوزان الخاصة بها) وتدريب الطبقات الكاملة الاتصال وتعديل أوزانها فقط أما الطريقة الثانية فيتم فيها تجميد أوزان الطبقات الالتفافية الأولى وتدريب الطبقات الأخيرة(تعديل أوزانها) أما الطريقة الثالثة فتعتمد على تعديل أوزان جميع الطبقات(حيث يتم استخدام أوزان الشبكة المدربة مسبقاً كأوزان ابتدائية بدلاً من ضبط الأوزان بطريقة عشوائية) وذلك باستخدام قاعدة بيانات BreakHis والتي تحتوي على صور مجهرية من أجل الحصول على شعاع السمات ثم المقارنة بين أكثر من نوع من خوارزميات تعلم الآلة لاستخدامها في مرحلة التصنيف

حيث أعطت RESNet50 مع مصنف الدعم الآلي الأداء الأفضل وحققت دقة تصل إلى 96.84%.

## 2- هدف البحث

يهدف البحث إلى تصميم نظام تشخيص بمساعدة الحاسب لتشخيص سرطان الثدي يقدم رأياً مساعداً للعنصر البشري وبالتالي المساعدة في تقليل الوفيات الناتجة عن التشخيص الخاطئ وذلك بالاعتماد على الشبكات العصبية الالتفافية ونقل التعلم بالإضافة إلى تطبيق تقنيات المعالجة المسبقة على قاعدة البيانات المستخدمة وتطبيق تقنيات حديثة لضبط المعاملات العليا الخاصة بالشبكة العصبونية العميقة من أجل الوصول إلى القيم المثالية بأسرع وقت وتحسين أداء النموذج .

## 3- مشكلة البحث

- الأبعاد المكانية الكبيرة لصور الماموغرام وبالتالي سوف تستغرق وقت طويل عند تدريب الشبكة من الصفر وبأوزان ابتدائية عشوائية.
- العدد المحدود لصور الماموغرام المتاحة لبناء الشبكات العصبية الالتفافية والذي يؤدي إلى حدوث مشكلة الحفظ الزائد للبيانات **overfitting** أثناء تدريب الشبكة.
- عدم التوازن بين الأصناف في قواعد البيانات الطبية حيث يمكن جمع عدد كبير من العينات السليمة مقارنة مع عدد العينات المصابة وبالتالي هذا يسبب انحياز النموذج بشكل أكبر نحو الصنف المسيطر (صنف العينات السليمة).
- الزمن الطويل اللازم لضبط قيم البارامترات العليا للشبكات العصبونية الالتفافية عند استخدام خوارزميات البحث التقليدية لضبط هذه البارامترات.

## 4- طرق البحث وأدواته

يرتكز البحث على ثلاث منظومات أساسية: الشبكة العصبونية الالتفافية العميقة و تقنية نقل التعلم و قاعدة البيانات.

وقد استخدمنا لبناء النموذج ما يلي:

1. Python 3.7: تم الاعتماد على لغة البايثون بسبب توافر المكتبات مفتوحة المصدر العديدة والتي تسهل عمليات المعالجة المسبقة للبيانات بالإضافة إلى المكتبات التي تتضمن خوارزميات التعلم العميق الجاهزة مثل tensorflow\Keras وبالتالي توفير الوقت و الجهد بدلاً من تطبيقها بشكل يدوي.

2. برنامج spyder الموجود ضمن بيئة anaconda .

3. Open-Source frameworks (Keras ,tensorflow ,Sklearn ,

Numpy, Seaborn, Matplotlib, Pandas).

4. حاسب شخصي (GeForce MX 130 GPU)

5. CUDA toolkit 10.1

6. مقاييس الأداء: بعد الانتهاء من تصميم النموذج والحصول على النتائج فإن الخطوة التالية هي معرفة مدى فعالية النموذج النهائي وتقييمه ويتم ذلك باستخدام مقاييس الأداء المختلفة وتعتبر مصفوفة التشتت Confusion Matrix هي الأكثر استخداماً لتقييم نماذج التصنيف سواء كان الهدف يتكون من صنفين أو أكثر من الأصناف وبناء عليها يمكن إيجاد مقاييس الأداء التالية: [20]

• **الدقة Accuracy:** هي عدد التنبؤات الصحيحة التي قام بها النموذج على عدد التنبؤات الكلي التي تم إجراؤها وتعد الدقة مقياساً جيداً عندما يكون عدد البيانات في الأصناف المدروسة متوازناً تقريباً ويتم حسابها بالعلاقة التالية:

$$Acc = \frac{Tp + Tn}{Tp + Tn + Fp + Fn} \quad (1)$$

**True Positive (TP):** هو عدد عينات الصنف الأول التي قام النموذج بتصنيفها بشكل صحيح.

**True Negative (TN):** هو عدد عينات الصنف الثاني والتي قام النموذج بتصنيفها بشكل صحيح.

**False Positive (FP):** العينات التي تنتمي للصنف الأول وقام النموذج بتصنيفها في الصنف الثاني.

**False Negative (FN):** العينات التي تنتمي للصنف الثاني وقام النموذج بتصنيفها في الصنف الأول.

- **الحساسية (sensitivity (recall):** تعرف بأنها نسبة عدد التوقعات الإيجابية الصحيحة ، وهي توضح قدرة النموذج على تجنب وضع الحالات السلبية على أنها إيجابية ويشير هذا المقياس إلى قدرة تحديد المرضى بشكل صحيح ويتم حسابها بالعلاقة:

$$Sen = \frac{Tp}{Tp + Fn} \quad (2)$$

- **الخصوصية (The specificity (precision):** يتم تعريفها على أنها نسبة السلبيات الفعلية ، والتي تم توقعها على أنها سلبية (سلبية حقيقية). يشير (3) إلى قدرة الاختبار على تحديد الأشخاص غير المصابين بالمرض بشكل صحيح ويتم حسابها بالعلاقة التالية:

$$Spec = \frac{Tn}{Tn + Fp}$$

- **F1-Score**: يمكن الجمع بين الخصوصية والحساسية معاً في مقياس أكثر إيجازاً، هو مقياس لدقة النموذج في مجموعة البيانات. يتم استخدامه لتقييم أنظمة التصنيف الثنائية ، والتي تصنف الأمثلة إلى موجبة أو سلبية ويتم تعريفها أيضاً على أنها المتوسط التوافقي لحساسية النموذج وخصوصيته.

$$F\_score = 2 * \frac{(sensitivity * specificity)}{sensitivity + specificity} \quad (4)$$

- **Receiver Operating characteristic curve (ROC Curve)**

هو رسم بياني يوضح أداء نموذج التصنيف في جميع عتبات التصنيف. يرسم هذا المنحنى باستخدام بارامترين: معدل الإيجابيات الصحيحة True Positive (TP) والذي يعبر عن حساسية النموذج بالإضافة إلى معدل السلبيات الخاطئة False Negative (FN) الذي يحسب من العلاقة

ا (5)

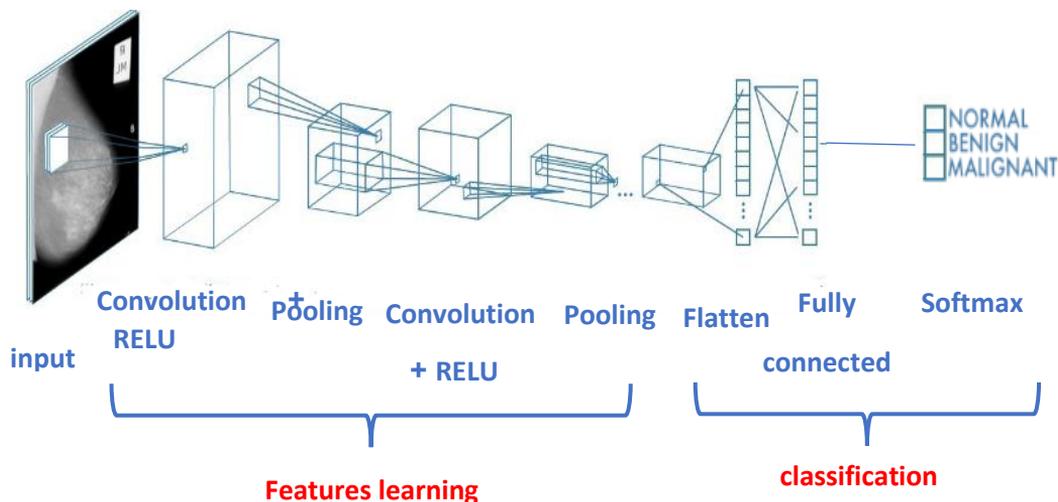
$$FPR = \frac{FP}{FP + TN}$$

يرسم منحنى True Positive Rate ROC مقابل False Positive Rate عند عتبات تصنيف مختلفة. يؤدي خفض عتبة التصنيف إلى تصنيف المزيد من العناصر على أنها إيجابية ، وبالتالي زيادة كل من الإيجابيات الخاطئة والإيجابيات الحقيقية و لحساب النقاط في منحنى Receiver Operating characteristic الاستقبال curve ، يمكننا تقييم نموذج الانحدار عدة مرات مع عتبات تصنيف مختلفة ، ولكن هذا سيكون غير فعال. توجد خوارزمية فعالة قائمة على الفرز يمكنها توفير هذه المعلومات لنا، تسمى المنطقة تحت المنحنى Area Under Curve (AUC).

- **Area Under ROC Curve**: يقيس المنطقة ثنائية الأبعاد بأكملها أسفل منحنى Receiver Operating Characteristic (ROC) و تتراوح قيمته من 0 إلى 1 وهي تعبر عن أداء الشبكة بالنسبة لصنف معين .

## 5- الشبكات العصبونية الالتفافية

يعتمد هيكل الشبكات العصبونية الالتفافية على مفاهيم الشبكات العصبونية التقليدية من خلال تكديس مجموعة من الطبقات الالتفافية وطبقات التجميع pooling layer لبناء النموذج بشكل كامل والموضحة بالشكل (2). إن الهدف من هذه الطبقات هو تقليل أبعاد الصور المدخلة إلى شكل بسيط بما يكفي ليتم معالجته بواسطة الطبقات كاملة الاتصال fully connected layer مع الاحتفاظ بالمعلومات المفيدة فقط من الصورة الأصلية [11].



الشكل (2): بنية الشبكة العصبونية الالتفافية التي تقوم بالتصنيف المتعدد (عينة سليمة-ورم حميد-ورم خبيث)

تتكون الشبكات العصبونية الالتفافية من الطبقات التالية: الطبقة الالتفافية Convolutional Layer، وطبقة التجميع Pooling Layer وطبقة المرتبطة بشكل كامل Fully connected Layer.

#### 1. الطبقة الالتفافية convolution layer: الخلايا العصبونية في الطبقات

الالتفافية الأولى موصولة فقط بالبكسل الموجود في مجالها الاستقبالي وغير متصلة بكل بكسل في الصورة. وبالمثل، فإن الخلايا العصبية الموجودة في الطبقات الالتفافية العميقة مرتبطة فقط بالخلايا العصبية في منطقة صغيرة من الطبقة السابقة. يتيح ذلك للشبكات العصبونية الالتفافية التركيز أولاً على السمات منخفضة المستوى، والتي يتم تجميعها تدريجياً في سمات ذات مستوى أعلى (أكثر تعقيداً) كلما زاد العمق ضمن الشبكة. كلما زاد تباعد الحقول المستقبلية كلما كانت الطبقة التالية أصغر، وبالتالي تقليل التعقيد بشكل كبير حيث يطبق في الطبقة الالتفافية مرشح (Filter ويُسمى أيضاً بـ kernel) من شأنه تحديد وجود سمات أو أنماط معينة في الصورة الأصلية (الدخل)، ثم إنه يُمكن استخدام عدّة مرشّحات بغية استخراج سمات مختلفة. يكون المرشّح ذو حجم صغير ليمسح الصورة كاملةً ويطبق العمليات الحسابية المناسبة بين قيم المرشّح والنقاط اللونية (Pixels) بغية استخراج السمات (Features) وعادة ما تكون الجداء الداخلي فيما بينها. يُعاد ضبط قيم المرشّح خلال عملية التدريب الدورية، وعند تدريب الشبكة لعدد مُعيّن من المرات (epochs)، تبدأ هذه المرشّحات بالبحث عن سمات مُتمايزة في الصورة بحيث توظّف الطبقات الخفية الأولى في استخراج السمات البسيطة والواضحة، مثل الحواف في الاتجاهات المختلفة، وما إلى ذلك. ومع التعمّق أكثر في الطبقات الخفية في الشبكة، تزداد درجة تعقيد السمات التي يجب تحديدها واستخراجها. وفي النهاية يتم تخزين قيم

الجداء الداخلي من أجل كل receptive field في مصفوفة أخرى تُدعى خريطة السمات Feature map والتي تُعطي معلومات عن وجود المُرشح في الصورة ومواقع ظهوره فيها.

2. **طبقة التجميع Pooling Layer:** تشبه طبقات التجميع الطبقات الالتفافية حيث ترتبط الخلايا العصبونية فقط بالخلايا العصبونية من منطقة صغيرة في الطبقة السابقة ، والفرق هو أن هذه الطبقة غير قابلة للتدريب لأن خلاياها العصبونية ليس لها أوزان . يتم استخدامها فقط لاختزال العينة (تقليل أبعادها) لتقليل الحمل على وحدة المعالجة الرسومية بالإضافة إلى تسريع عملية التدريب. يتم ذلك عن طريق حساب إجمالي المدخلات بناءً على دالة ، والتي يمكن أن تكون إما دالة عظمى max pooling أو دالة متوسطة average pooling ، ويعيد الحد الأقصى للتجميع القيمة القصوى للجزء المغطى من الصورة ، في حين أن متوسط التجميع يعيد متوسط جميع القيم. يُعد التجميع الأقصى max pooling هو الخيار الأفضل في الشبكات العصبونية الالتفافية لأنه يحتفظ بالسمات الأكثر أهمية فقط ويعمل كمزيل للضجيج بالإضافة إلى أنه لن يتم التعطل عن تغذية الشبكة بالصور التي تحتوي على سمات بأحجام مختلفة عن تلك التي تظهر في عينات التدريب.

3. **الطبقة كاملة الارتباط fully connected layer:** تُستخدم توابع التنشيط لربط الطبقات الالتفافية وطبقات التجميع مع بعضها البعض. إن تابع التنشيط الأكثر استخداماً في الشبكات العصبونية الالتفافية هو تابع الوحدة الخطية المصححة Rectified Linear Unit (ReLU)، وفي نهاية مجموعة الطبقات الالتفافية والتجميع، يتم وضع الطبقة كاملة الارتباط. تأخذ هذه الشبكة العصبية العميقة المخرجات المسطحة flatten للطبقات الالتفافية والتجميع المكسدة (والتي يتم

تحويلها من 2D إلى 1D) وتؤدي مهام التصنيف باستخدام السمات التي تعلمتها الطبقات الالتفافية بتنسيق مكثف. اعتماداً على عدد الأصناف ، يمكن استخدام تابع التنشيط softmax للتصنيف متعدد الفئات أو تابع السيغمويد sigmoid للتصنيف الثنائي .

## 6- نقل التعلم

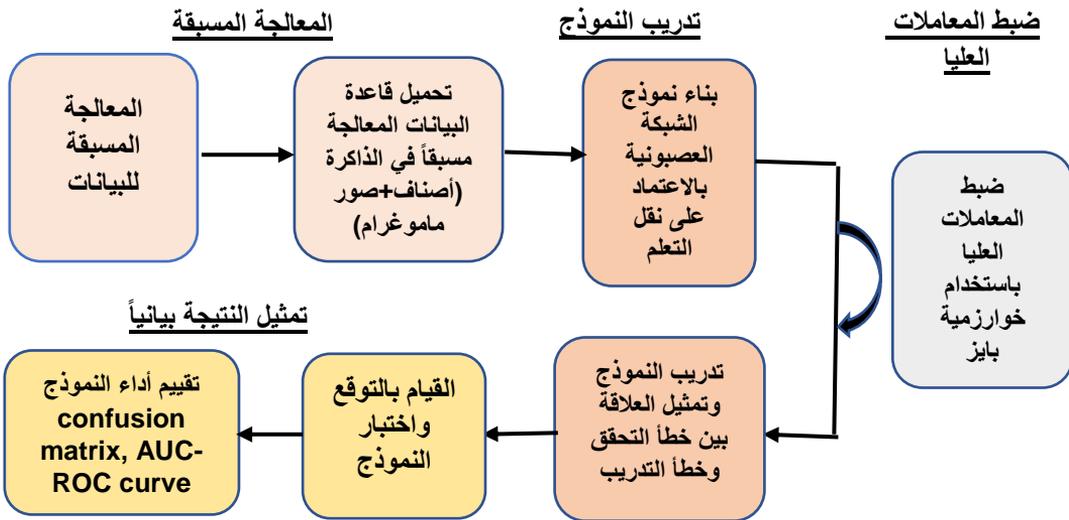
هو أسلوب تعلم عميق شائع الاستخدام عندما يتوفر قدر ضئيل من البيانات، والذي يستخدم نماذج الشبكات العصبونية الالتفافية المدربة مسبقاً على مجموعات بيانات عامة كبيرة. يمكن ذلك من نقل المعرفة التي تم جمعها بواسطة هذه الشبكات عالية الأداء في المجالات العامة التي تحتوي على مجموعات بيانات أكبر إلى مجال ذي صلة مثل الصور الطبية، وقد تم تصميم هذه النماذج لتصنيف ملايين الصور عبر آلاف الفئات المختلفة ويمكن بسهولة أن تتكيف مع أي مهمة تصنيف عن طريق استبدال الطبقة الأخيرة Dense Layer التي تقوم بعملية التنبؤ الفعلي بحيث تحتوي على خلية عصبية واحدة لكل فئة للتنبؤ. [12]

## 7- نظام تشخيص سرطان الثدي القائم على التعلم العميق

يمكن تقسيم عملية تصميم نظام التعلم العميق الذي تم تنفيذه لمهمة الكشف عن سرطان الثدي إلى أربع مراحل متميزة والموضحة بالشكل (3) إلى:

- **المعالجة المسبقة للبيانات data pre-processing**: يتم تحميل قاعدة البيانات في الذاكرة ومعالجتها وربطها مع ملف الأصناف من أجل تجهيزها لمهمة التصنيف.

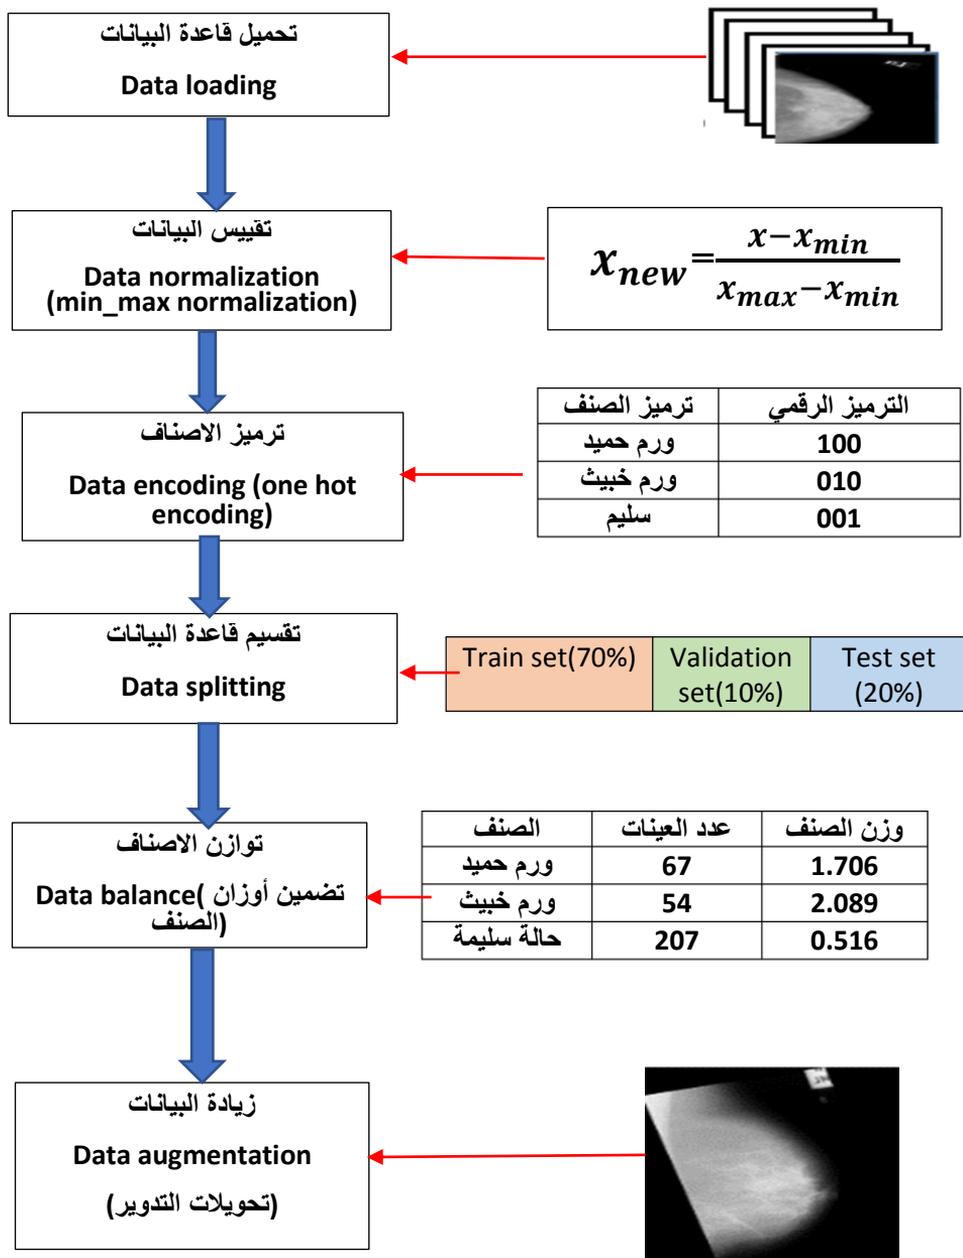
- **نموذج التدريب Model Training**: إنشاء نموذج الشبكة العصبونية الالتفافية الذي يمكن أن يتناسب مع البيانات ويصبح قادر على التعلم من مجموعة عينات التدريب حيث تم المقارنة بين مجموعة من الشبكات المدربة مسبقاً لاختيار المعمارية الأفضل.
- **ضبط المعاملات العليا hyper parameters tuning**: سيتم الاعتماد على خوارزمية بايز لضبط المعاملات العليا الخاصة بالشبكة المدربة مسبقاً التي أعطت الأداء الأفضل بدلاً من الاعتماد على الطريقة العشوائية من أجل الوصول للنموذج الأمثل وخلال زمن أقل.
- **تقييم أداء النموذج Model Evaluating**: يتم اختبار النموذج على عينات الاختبار المأخوذة من قاعدة البيانات و تقييم أدائه بالاعتماد على مصفوفة التشتت confusion matrix و قيمة المنطقة تحت منحنى خصائص تشغيل الاستقبال Area Under ROC curve



الشكل (3): مخطط التدفق الذي يوضح مراحل تصميم نظام تشخيص سرطان الثدي المعتمد

تم استخدام مجموعة بيانات Mini-Mias والتي تعتبر صغيرة الحجم (339 ميغا بايت) تتضمن 322 صورة رمادية بأبعاد 1024\*1024 لذلك يمكن تحميلها في الذاكرة دون أي تطبيق لأي تقنية تحسين تحميل البيانات ثم يتم تغيير حجم البيانات إلى الحجم المستهدف (224\*224) عند تحميل البيانات لتصغيرها ولتجنب وجود أحجام إدخال غير متناسقة حيث تكشف مراقبة شدة البكسل للصور الموجودة في مجموعات البيانات أنها تتوافق مع أعداد صحيحة تتراوح من 0 إلى 255. ومع ذلك، نظرًا لأن الأوزان في الشبكات العصبونية صغيرة، فإن وجود مثل هذه القيم الكبيرة للمدخلات يمكن أن يؤدي إلى تعطيل وإبطاء عملية التدريب ، مما يؤدي في النهاية إلى دقة منخفضة. لذلك، يمكن أن يساعد تقييس قيم البكسلات وتحويلها إلى قيم موجودة ضمن نطاق من 0 إلى 1 إلى التخلص من هذه المشكلة من خلال ضمان أن تكون جميع القيم صغيرة. في المرحلة التالية ونظرًا لأن أسماء الأصناف الخاصة بكل صورة ماموغرام موجودة على شكل تنسيق محرفي، يجب تحويلها إلى تنسيق رقمي ونظرًا لطبيعة الأصناف (ثلاث فئات فقط) تم اختيار ترميز one hot encoding لمجموعة بيانات mini MIAS، ثم تقسيم قاعدة البيانات إلى مجموعة التدريب إلى 70% تدريب و 10% تطوير و 20% اختبار حيث تستخدم مجموعة التطوير من أجل ضبط المعاملات العليا واختيار القيم الأمثل لها ثم يتم استخدام مجموعة الاختبار في تقييم الأداء النهائي للنموذج. ولحل مشكلة عدم توازن توزيع العينات ضمن الأصناف كان الخيار الأفضل من حيث قوة الحوسبة و التي لا تتطلب إضافة مجموعة بيانات جديدة هو إضافة أوزان الأصناف عند تدريب النموذج، والذي يؤدي إلى تقليل قيمة تابع الخطأ عن طريق اعطاء أهمية أكبر للأصناف الأقل ولمعالجة مشكلة مجموعات البيانات الصغيرة ونظرًا لصغر قاعدة البيانات تم استخدام تقنية زيادة البيانات التي تستخدم لتجنب حدوث مشكلة حفظ البيانات الزائد overfitting عند محاولة تعلم نماذج التعلم العميق المعقدة التي تحتوي على عدد كبير من البارامترات

باستخدام مجموعة بيانات صغيرة حيث تم الاعتماد على تحويلات التدوير فقط في زيادة البيانات باعتبارها التحويل الأكثر واقعية والذي يستخدم من قبل أخصائي الأشعة ويبين الشكل (4) مراحل المعالجة المسبقة مع نتيجة كل مرحلة.



الشكل(4): يبين مراحل المعالجة المسبقة التي تمت على قاعدة بيانات mini-mias مع نتيجة كل مرحلة

## 2-7 نموذج التدريب

يمكن تقسيم عملية بناء النموذج الخاص بتشخيص سرطان الثدي إلى أربع مراحل أساسية:

1. بناء نموذج الشبكة العصبونية الالتفافية simple base model و المبين في الشكل (8) وتقييم أدائه.

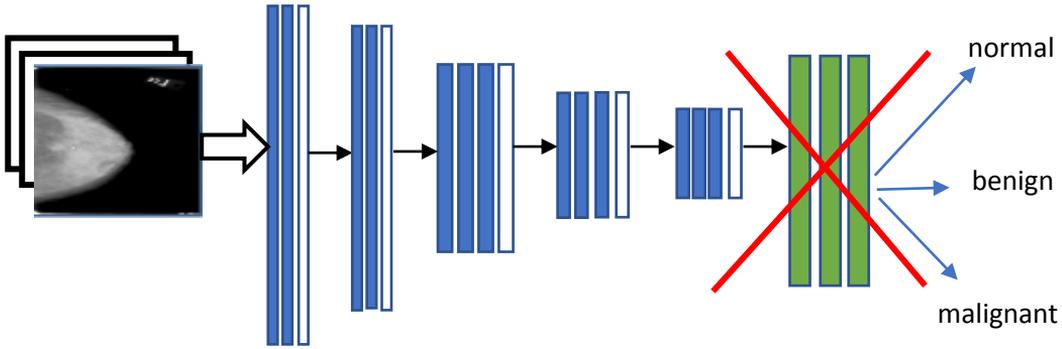
2. تدريب معماريات مختلفة من النماذج المدربة مسبقاً والمقارنة بينها لاختيار النموذج الأفضل.

3. تطبيق تقنيات التسوية regularization من أجل زيادة تعميم النموذج الأمثل والحصول على أداء أفضل.

4. ضبط البارامترات العليا hyper parameter tuning باستخدام خوارزمية بايز والحصول على النموذج النهائي.

في المرحلة التالية، سيتم استخدام تقنية نقل التعلم **transfer learning** و هو أسلوب تعلم عميق شائع الاستخدام عندما يتوفر قدر ضئيل من البيانات ، والذي يستخدم نماذج الشبكات المدربة مسبقاً على مجموعات بيانات عامة كبيرة. يمكن ذلك من نقل المعرفة التي تم جمعها بواسطة شبكات عالية الأداء في المجالات العامة الأخرى التي تحتوي على مجموعات بيانات أكبر إلى مجال ذي صلة مثل الصور الطبية ، وقد تم تصميم هذه النماذج لتصنيف ملايين الصور عبر آلاف الفئات المختلفة ويمكن بسهولة أن تتكيف مع أي مهمة تصنيف عن طريق استبدال الطبقة الأخيرة Dense Layer التي تقوم بعملية التنبؤ الفعلي بحيث تحتوي على عصبون واحد لكل فئة بطبقة تحتوي على

عدد عصبونات تناسب التطبيق المراد بناؤه و يبين الشكل (5) معمارية شبكة VGG16 التي تم ضبط بارامتراتهما من أجل القيام بعملية تشخيص سرطان الثدي.



الشكل (5): يوضح تطبيق نقل التعلم على بنية نموذج VGG16

تم المقارنة بين أربع نماذج مدربة مسبقاً (VGG16, MobileNetV2, InceptionV3, ResNet50) ثم القيام بعملية تعديل النماذج عن طريق استبدال الطبقات الأخيرة بطبقات تحتوي على عدد 256 عصبون بدلاً من 4096 عصبون حيث تم تصميم هذه النماذج في الأصل لتصنيف ما يصل إلى 1000 فئة وبالتالي تحتوي على طبقات بعدد عصبونات كبير كما سيتم إضافة طبقات الإسقاط وهي طريقة تسوية regularization من أجل زيادة تعميم الشبكة وحل مشكلة الحفظ الزائد للبيانات overfitting.

## 8- النتائج ومناقشتها

تم استخدام قاعدة بيانات عالمية Mini-mias وهي قاعدة بيانات مجانية متاحة على الانترنت [13] تحتوي على 322 صورة ماموغرام بالإضافة إلى ملف الوصف النصي Info.txt ويشمل جمهورنا المستهدف الأطباء والممرضين وأخصائي الأشعة وطلاب الطب وغيرهم من المهتمين بالمعرفة الطبية.

## عدد صور الماموغرام:

تشمل قاعدة البيانات على 322 صورة ماموغرام مقسمة إلى سبع أصناف :

- التكلسات الدقيقة (CALC) calcification والتي تنتج عن ترسب كربونات الكالسيوم الموجودة ضمن نسيج الثدي (34 عينة)
  - الكتل المتناظرة (CIRC) Circumscribed masses عبارة عن كتل غير طبيعية موجودة ضمن نسيج الثدي (24 عينة)
  - الكتل المتشققة (SPIC) Spiculated masses عبارة عن كتل بأشكال شاذة تظهر ضمن نسيج الثدي (24 عينة).
  - الحالات الشاذة المتنوعة (MISC) ill-defined masses, others: وجود أشكال متنوعة من الكتل و التكلسات الدقيقة معاً ضمن نسيج الثدي (18 عينة)
  - نسيج ثدي تالف (ARCH) Architectural Distortion تحتوي على أنسجة تالفة ضمن الثدي (12 عينة)
  - كتل ذات كثافة متنوعة (ASYM) Asymmetry: زيادة في كثافة الكتل الموجودة ضمن النسيج والتي تعبر عن حالة متطورة من الورم (21 عينة)
  - الحالات الطبيعية (NORM): والتي تعبر عن العينات التي لا تحتوي أي عناصر شاذة (كتل-تكلسات) أو تشوهات ضمن نسيج الثدي. (189 عينة)
- تقسم العينات الموجودة ضمن الأصناف السابقة تبعاً لدرجة الخطورة Severity إلى ثلاث أصناف: 201 : عينة سليمة-67: ورم حميد-54: ورم خبيث.

## بارامترات الصور:

— إن العينات الموجودة ضمن قاعدة البيانات مخزنة باستخدام التنسيق Portable Gray Map (PGM) و سيتم تحويلها إلى Portable Network Graphic PNG حيث يحتاج امتداد PGM إلى برمجيات خاصة للتعامل معه بينما يعتبر PNG أكثر مرونة.

- أبعاد الصور 1024\*1024 وهي عبارة عن صور رمادية Grayscale حيث يبلغ عدد السويات الرمادية:8 بت وتتراوح قيم بكسلات الصورة بين 0 و 255.

- يحتوي الملف النصي Info.txt على رقم المعرف الخاص بالصورة - نوع نسيج الثدي- نوع الحالة غير الطبيعية (كتلة-تكتلات دقيقة-سليمة) و درجة الخطورة (حميد-خبيث) بالإضافة إلى إحداثيات مركز وجود الحالة غير الطبيعية ونصف قطرها.

تم اختبار النموذج على عينات الاختبار التي تحتوي على 64 عينة والمقارنة من أجل إيجاد النموذج الأفضل ثم ضبط بارامتراته والحصول على النموذج النهائي وفق ما يلي:

#### (A) نموذج الشبكة المدربة مسبقاً المستخدم Base model used:

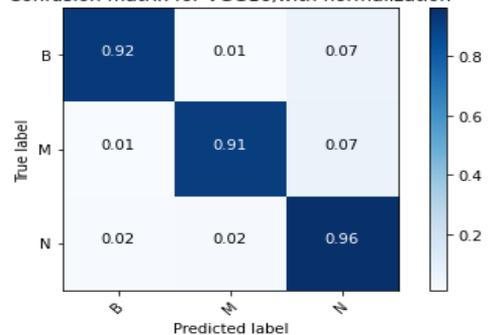
أربعة نماذج شبكات عصبونية التلافيفية مدربة مسبقاً على قاعدة البيانات imageNet (VGG16, ResNet50, Inception V3, MobileNetV2) تم تطبيقها على أنها نموذج الأساس base\_model . بالنسبة لهذا الاختبار ، يتم استخدام مجموعة بيانات mini-mias مع الصور الكاملة دون القيام بأي عملية اقتطاع على الصور و التي تم إعادة تحجيمها إلى 3 × 224×224 بكسل وهو يطابق أبعاد الصور الموجودة ضمن قاعدة البيانات ImageNet والتي تم تدريب الشبكات السابقة عليها، وحجم المجموعة batch\_size=128 بالإضافة إلى تجميد جميع طبقات النموذج وتدريب طبقة التصنيف فقط حيث تم استبدال الطبقة الأصلية للنموذج المدرب مسبقاً والتي تحتوي على 1000 عصبون بطبقة تحتوي على ثلاث عصبونات(تصنيف متعدد).

معمارية الشبكة المدربة	إجمالي الدقة	الحساسية	الخصوصية	F1 Score
VGG16	93.76%	94.63%	94.62%	94.62%
MobileNetV2	62.6%	65.28%	62.6%	63.5%
InceptionV3	60.3%	67.15%	60.3%	61.95%
ResNet50	87.67%	87.6%	87.67%	87.6%

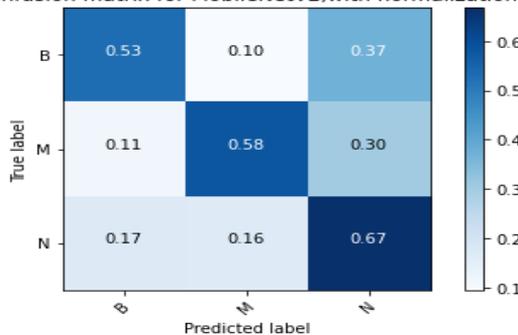
الجدول (1): يبين مقارنة بين مقاييس الأداء الخاصة بالمعماريات المدربة مسبقاً

النتائج الموجودة في الجدول (1) تكشف بوضوح أن معمارية VGG16 أعطت الأداء الأفضل بين المعماريات السابقة. سيتم استخدام بنية VGG16 وضبط بارامتراتهما في التجارب التالية من أجل الوصول إلى النموذج النهائي.

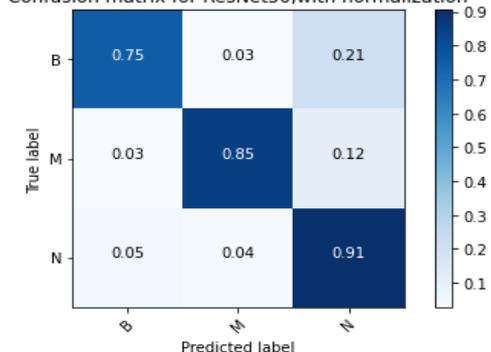
Confusion matrix for VGG16,with normalization



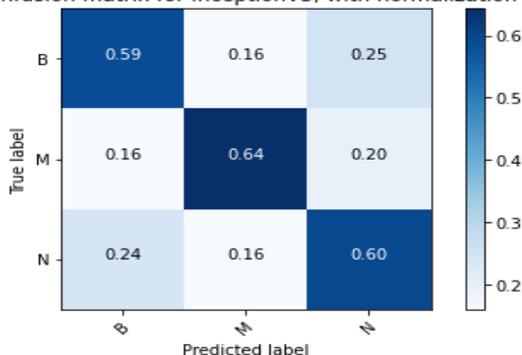
Confusion matrix for MobileNetV2,with normalization



Confusion matrix for ResNet50,with normalization



Confusion matrix for InceptionV3, with normalization

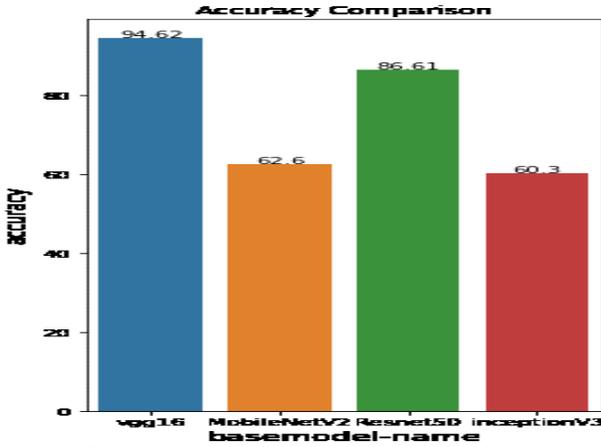


الشكل (6): يوضح مصفوفة التشتت لكل من الشبكات المدربة مسبقاً وذلك بعد استبدال

طبقة التصنيف لنموذج الأساس بطبقة تحتوي على ثلاث عصبونات

أعطت شبكة MOBILENetV2 وشبكة InceptionV3 الأداء الأقل حيث تصمم هذه الشبكات من أجل تقليل الحاجة للموارد المستخدمة وهذا الأمر لا يهمننا في المجال الطبي إنما الأهم هو دقة التشخيص بالإضافة إلى أن شبكة VGG16 تفوقت على شبكة ReNet50 حيث أنها ذات معمارية عميقة (نموذج معقد) بالنسبة إلى قاعدة البيانات

الموجودة وبالتالي سيؤدي ذلك إلى حدوث مشكلة الحفظ الزائد للبيانات **overfitting** ويوضح الشكل (6) مصفوفة التشتت **confusion matrix** الخاصة بالنماذج السابقة على عينات الاختبار كما يبين الشكل (7) مقارنة بين إجمالي معدل الدقة بالنسبة للأصناف الثلاثة حيث تم اختبار الشبكات السابقة على عينات الاختبار و أعطت شبكة VGG16 دقة تعادل 94.62% .



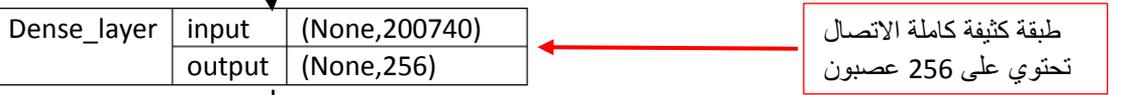
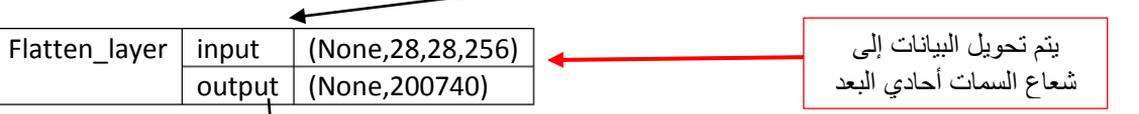
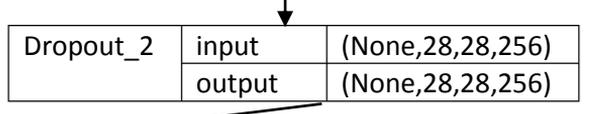
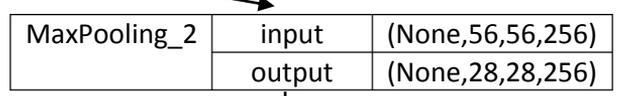
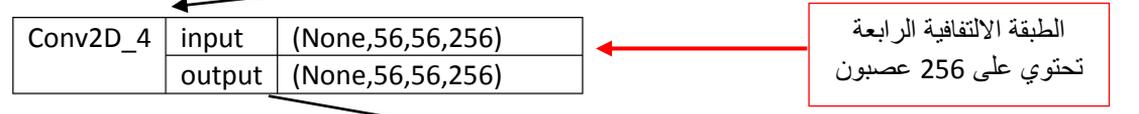
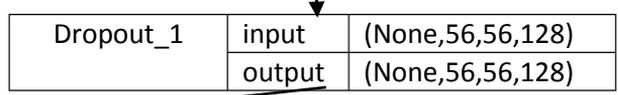
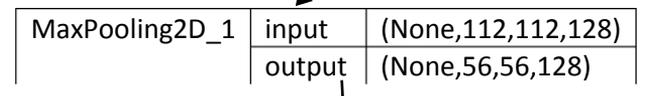
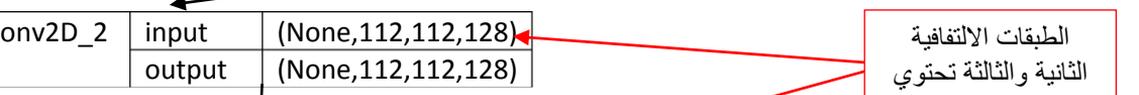
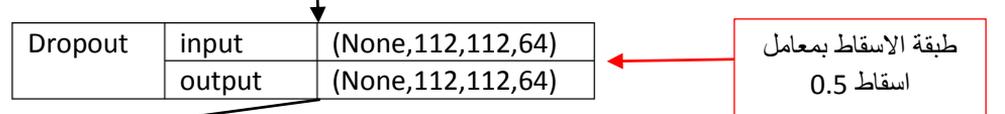
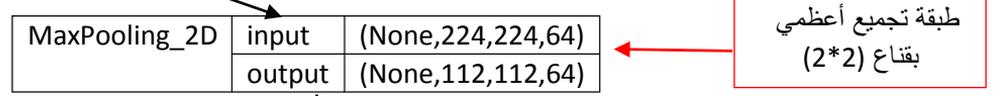
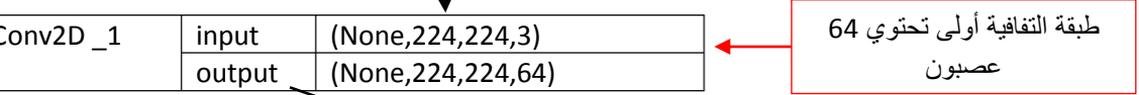
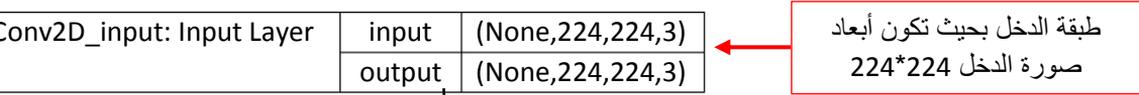
الشكل (7):مقارنة بين إجمالي الدقة للمعاريات المدربة مسبقاً

#### (b) طرق تطبيق تقنية نقل التعلم:

تم المقارنة بين بناء نموذج شبكة عصبونية التفاضلية وتهيئته بأوزان بدائية عشوائية بعد أن تم ضبط بارامترات باستخدام خوارزمية بايز وبين نماذج مدربة مسبقاً على قاعدة بيانات ImageNet وباستخدام نسب مختلفة من نقل التعلم. تم تطبيق ثلاث تجارب مختلفة باستخدام بنية الشبكة العصبونية الالتفافية ثم اختبارها لتقييم تأثير نقل التعلم من مجموعة بيانات ImageNet لمجموعة بيانات mini mias وهي:

- نقل التعلم لجميع أوزان الطبقة (طبقات VGG16) وتدريب طبقة التصنيف فقط.

- نقل التعلم من أوزان ImageNet للطبقات الأولى فقط لشبكة VGG16 (حيث تم تجميد الأوزان البدائية للطبقات الأولى ثم استبدال الطبقات الأخيرة بطبقات جديدة وضبط بارامتراتهما و القيام بتدريب الطبقات الجديدة على قاعدة بيانات (mini mias).
  - عدم تطبيق نقل التعلم وتدريب نموذج شبكة عصبونية التلافيفية بأوزان بدائية عشوائية على قاعدة بيانات MINI-MIAS.
- ويوضح الشكل(8) معمارية نموذج الشبكة العصبية الالتفافية الذي تم بناؤه حيث تم الوصول إلى قيم البارامترات العليا المثلى باستخدام خوارزمية بايز. تم استخدام تابع تنشيط الوحدة الخطية المصححة Rectified Linear Unit(Relu) ضمن الطبقات الخفية وتابع التنشيط Softmax ضمن طبقة التصنيف وقيمة معامل الاسقاط 0.5.



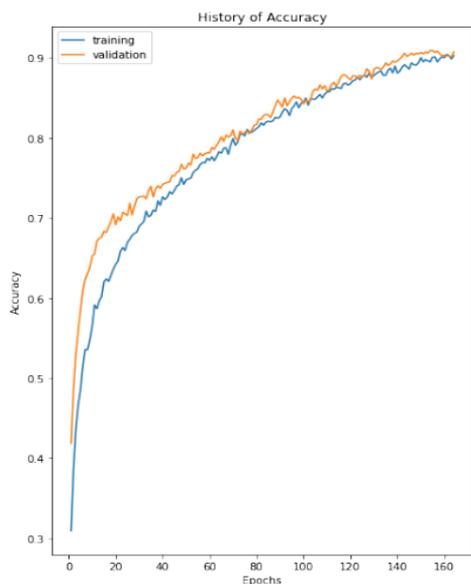
ويوضح الجدول (2) مقاييس الأداء التي تم الحصول عليها عند إجراء كل تجربة حيث تم استخدام معمارية VGG16 باعتبارها أعطت الأداء الأفضل بالإضافة إلى دراسة تأثير تطبيق زيادة البيانات Data Augmentation على أداء النموذج .

نقل التعلم	زيادة البيانات	إجمالي الدقة	الحساسية	الخصوصية	F1 score
VGG16 layers ImageNet transfer learning	نعم	93.76%	94.63%	94.62%	94.62%
No transfer learning (random weights)	نعم	87.72%	87.74%	87.72%	87.69%
VGG16 layers (fine tuning) ImageNet transfer learning	لا	32.65%	40.63%	32.65%	34%
<b>VGG16 layers (fine tuning) ImageNet transfer learning</b>	<b>نعم</b>	<b>95.31%</b>	<b>95.32%</b>	<b>95.31%</b>	<b>95.28%</b>

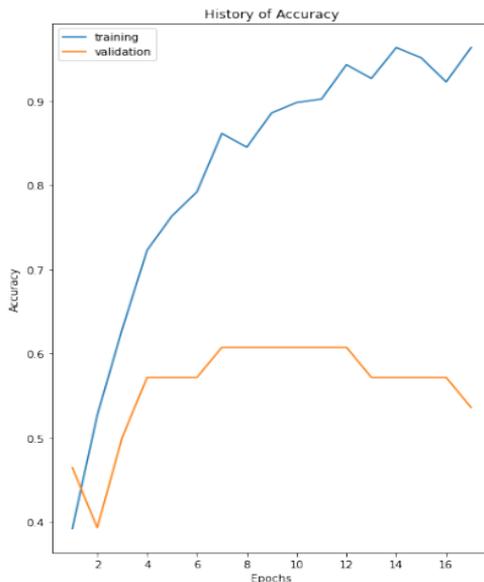
الجدول (2): مقاييس الأداء عند تطبيق نسب مختلفة من نقل التعلم على مجموعة الاختبار المأخوذة من قاعدة بيانات mini-mias

النتائج الواردة في الجدول (2) تشير بوضوح إلى أن أي شكل من أشكال نقل التعلم أفضل من التهيئة العشوائية للأوزان وذلك باستخدام مجموعة البيانات الصغيرة ومن ناحية أخرى فإن نقل الكثير من التعلم باستخدام جميع الأوزان من النموذج الذي تم تدريبه على مجموعة بيانات ImageNet لا يُعمم جيداً مجموعة بيانات mini-mias لذلك كان الأداء الأفضل هو تهيئة الطبقات الأولى بالأوزان الخاصة بالشبكة العصبية المدربة المسبقة والتي تقوم بعملية استخلاص السمات منخفضة المستوى low level-features مثل الحواف واستبدال الطبقات الأخيرة التي تحتوي على 4096 عصبون بطبقة تحتوي

على 256 عصبون والتي تعد مناسبة بشكل أفضل عند تصنيف الأصناف الثلاثة حيث أن شبكة VGG16 كانت مدربة من أجل تصنيف 1000 صنف وإضافة طبقات drop out من أجل زيادة تعميم النموذج و قد تم تحديد عدد العصبونات الأمثل وقيمة معامل الاسقاط باستخدام خوارزمية بايز لضبط البارامترات العليا كما تبين النتائج السابقة أهمية تطبيق زيادة البيانات على مجموعة التدريب حيث تم تطبيق تحويلات التدوير بزوايا مختلفة وهو التحويل الأنسب و الأكثر واقعية والذي يستخدمه أخصائي الأشعة من أجل الحصول على رؤية أوضح لصورة الماموغرام بحيث أصبحت عدد عينات التدريب 14490 عينة والذي ساعد النموذج على التعلم بشكل أفضل والحصول على دقة أعلى أما عدم تطبيق زيادة البيانات على نفس المعمارية السابقة أعطت أداء سيء حيث أن تطبيق نقل التعلم فقط على مجموعة التدريب الصغيرة (258 عينة) سوف يؤدي إلى حدوث مشكلة الحفظ الزائد للبيانات حيث يعطي النموذج دقة عالية في مرحلة التدريب و دقة منخفضة جداً في مرحلة التطوير والاختبار والموضحة بالشكل(9) والشكل (10) الذي يوضحان العلاقة بين دقة التدريب ودقة التطوير عند تدريب نموذج VGG16 الذي تم ضبط بارامتراته وذلك في حالة تطبيق زيادة البيانات وعدم تطبيقها حيث في حالة عدم تطبيق زيادة البيانات نلاحظ ازدياد دقة التدريب بازدياد عدد مرات تكرار تدريب النموذج Epochs بينما تتخفض دقة التطوير بشكل مستمر ويعطي النموذج أداء سيء بينما عند تطبيق زيادة البيانات نلاحظ ازدياد دقة التطوير والتدريب معاً بازدياد عدد مرات تكرار تدريب النموذج حتى نحصل على الأداء الأمثل.



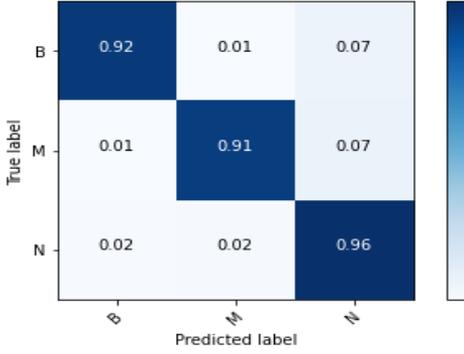
الشكل(10):علاقة دقة التدريب و دقة التطوير مع عدد مرات التدريب في حال تطبيق زيادة البيانات



الشكل(9):علاقة دقة التدريب و دقة التطوير مع عدد مرات التدريب في حال عدم تطبيق زيادة البيانات

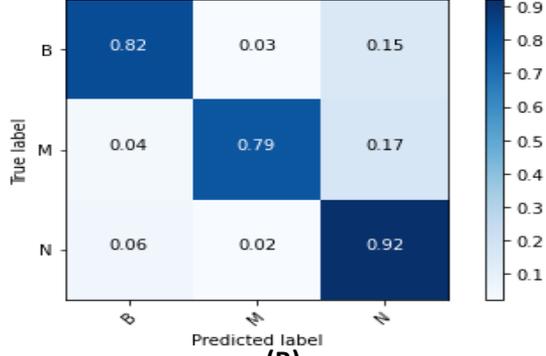
وعند تطبيق زيادة البيانات نلاحظ أن النموذج النهائي احتاج إلى عدد مرات تدريب أكثر وبالتالي زمن أطول في مرحلة التدريب قبل الوصول إلى الدقة الأمثل حيث تم التوقف عن عملية التدريب عند الوصول إلى 164 تكرار وذلك باستخدام تقنية التوقف المبكر early stopping والتي تقوم بإيقاف تدريب النموذج عند ثبات قيمة الدقة عند قيمة معينة وعدم تحسن قيمتها لضمان عدم حدوث مشكلة الحفظ الزائد للبيانات overfitting والوصول إلى الأداء المطلوب ويبين الشكل(11)مقاييس الأداء الخاصة بالتجارب السابقة حيث أعطى نموذج شبكة VGG16 المعدل الأداء الأمثل.

Confusion matrix for VGG16,with normalization



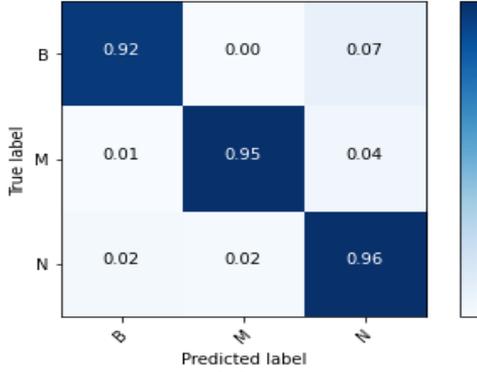
(A)

Confusion matrix for CNN, with normalization



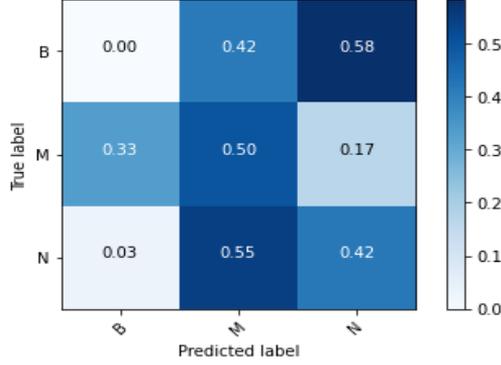
(B)

Confusion matrix for VGG16,with normalization



(C)

Confusion matrix with no augmentation, with normalization

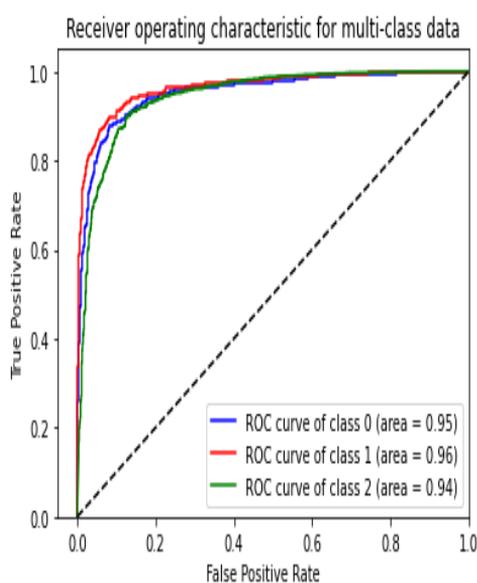
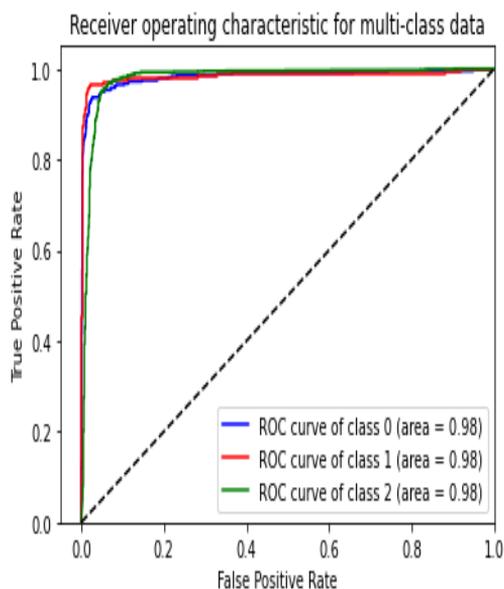


(D)

الشكل (11): مصفوفة التشنت الناتجة عن اختبار النماذج السابقة على عينات الاختبار المأخوذة من قاعدة بيانات MINI- (A): VGG16- (B): CNN بأوزان عشوائية- (C): VGG16 (زيادة البيانات وضبط بارامترات)- (D): VGG16 (ضبط بارامترات وبدون تطبيق زيادة بيانات)

في نظامنا المقترح تم استخدام 64 عينة اختبار و أعطى النظام دقة **95.31%** وحساسية **95.32%** وقيمة خصوصية **95.31%** وقيمة **F1-score 95.28%**.

ويوضح الشكل (12) Receiver Operating Characteristic (ROC CURVE) بعد تدريب النموذج النهائي على قاعدة البيانات التي تحتوي على 14490 عينة تدريب (تم تطبيق تحويلات التدوير على قاعدة البيانات الأصلية) ثم اختبار النموذج على عينات الاختبار.



الشكل(12):مخطط ROC CURVE للشبكة VGG16 التي تم ضبط بارامتراتهما باستخدام خوارزمية بايز

الشكل(13):مخطط ROC Curve للشبكة العصبية الالتفافية التي تم بناؤها من الصفر باستخدام خوارزمية بايز

من الشكل (12) يتضح أن النموذج النهائي المعدل المقترح له قيمة Area Under Curve تبلغ 98 %. هذا أفضل من معيارنا لقيمة AUC البالغة 88% من Li Shen et al [11]. بالإضافة إلى ذلك يوضح الشكل السابق الفرق بين قيمة المنطقة تحت المنحني Area Under Curve للأصناف الثلاثة للشبكة العصبية الالتفافية التي تم بناؤها من الصفر وتهيئتها بأوزان عشوائية وبين قيمة المنطقة تحت المنحني Area Under Curve لشبكة VGG16 التي تم ضبط بارامتراتهما حيث أعطت تقنية نقل التعلم نتيجة أفضل بالنسبة للأصناف الثلاثة.

ويوضح الجدول (3) مقارنة النظام المقترح مع الدراسات السابقة:

الباحث	قاعدة البيانات	الطريقة المستخدمة	الدقة
Daniel,2016[4]	DDSM	GoogleNet	(تصنيف ثنائي)92.4%
Jaafar,2017[6]	Mini-mias DDSM	CNN with SVM	(تصنيف ثنائي)92%
Prabhpeet,2019[7]	Mini-mias	CNN with MCSVM	عينة طبيعية 95% ورم حميد 92% ورم خبيث 93%
Dina,2019[8]	DDSM,CBIS DDSM	AlexNet	(تصنيف ثنائي)73.62%
Aditya,2020[9]	DDSM	VGG16	(تصنيف ثنائي)88.3%
النظام المقترح	Mini-mias	Vgg16(fine tuning) with data augmentation	96% صنف سليم 92% ورم حميد 95% ورم خبيث (تصنيف متعدد)AUC=98%

الجدول (3):يوضح مقارنة النظام المقترح مع الدراسات السابقة

تم بناء نظام قادر على القيام بالتشخيص المتعدد(عينة طبيعية -ورم حميد-ورم خبيث) حيث أعطى النظام المقترح حساسية أفضل من الدراسات السابقة وخاصة بالنسبة لصنف الورم الخبيث وبالتالي تقليل نسبة الوفيات الناتجة عن تشخيص العينة الورم الخبيث على أنها عينة طبيعية.

## 9- الاستنتاجات

كان الهدف الرئيسي من هذا البحث هو استخدام تقنيات التعلم العميق المختلفة من أجل بناء نظام قادر على تشخيص سرطان الثدي في صور الماموغرام. أثبتت النتائج فعالية استخدام الشبكات العصبية الالتفافية على صور الماموغرام من أجل تشخيص الحالات السليمة بالإضافة إلى كشف الكتل غير الطبيعية في الثدي حيث تم استخدام معماريات مختلفة من الشبكات العصبونية الالتفافية المدربة مسبقاً ومقارنتها مع شبكة عصبونية

التفافية تم إنشاؤها وتهيئتها بأوزان ابتدائية عشوائية حيث تم اثبات أن أي نوع من أنواع نقل التعلم أعطى الأداء الأفضل عند التعامل مع البيانات الطبية ذات الحجم الصغير بدلاً من تهيئة الشبكة بالكامل بأوزان عشوائية. أعطت شبكة VGG16 الأداء الأفضل حيث أن معمارية هذه الشبكات كانت الأفضل بالنسبة لطبيعة قاعدة البيانات الموجودة لذلك تم اعتمادها كنموذج الأساس و القيام بعملية ضبط البارامترات fine tuning واستبدال الطبقات الأخيرة بطبقات أخرى ثم تدريب الطبقات الجديدة فقط مع الاحتفاظ بأوزان الطبقات الأولى باعتبارها مسؤولة عن استخراج السمات منخفضة المستوى low-level-features بالإضافة إلى أن تطبيق تقنية زيادة البيانات (تطبيق تحويلات التدوير) مع استخدام تقنية نقل التعلم حسنت من الدقة وحلت مشكلة حفظ البيانات الزائد من خلال تدريب النموذج على عدد عينات أكبر وقد حقق النموذج دقة 95.31%. تم حل مشكلة قاعدة البيانات الغير متوازنة عن طريق حساب أوزان الأصناف و إدخالها في مرحلة التدريب و قد حقق النموذج حساسية عالية بالنسبة للأصناف الثلاثة حيث أعطى حساسية 92% للورم الحميد و 93% للورم الخبيث و 96% للعينات الطبيعية بالإضافة إلى أن بناء نموذج تصنيف باستخدام الصور الكاملة يسمح بإمكانية نقل التعلم من قاعدة بيانات mini-mias إلى قاعدة بيانات أخرى تحتوي على صور ماموغرام مثل Digital Database for Screening Mammography (DDSM) وتطوير مصنف يعطي أداء أقوى. إن أنظمة تشخيص سرطان الثدي بالاعتماد على الشبكات العصبونية الالتفافية حققت أداء عالي في اكتشاف وتشخيص سرطان الثدي في صور الماموغرام وبالتالي سوف تتكون مفيدة لتحسين الأداء التشخيصي لأخصائي الأشعة/للأطباء في الكشف المبكر عن المرض بالإضافة إلى تقليل الوفيات الناتجة عن التشخيص الخاطئ.

## 10- التوصيات

إمكانية استخدام معماريات جديدة من الشبكات العصبية المدربة المسبقة بالإضافة إلى طرق ضبط بارامترات جديدة وتطبيق تقنيات أخرى لحل مشكلة قاعدة البيانات الغير متوازنة بالإضافة إلى أن استخدام قواعد بيانات حقيقية بحجم أكبر بدلاً من تطبيق زيادة البيانات سوف يعطي نتائج أكثر دقة وواقعية ويساعد على بناء نظام تشخيص أقوى وبأداء أفضل.

## 11- المراجع

- [1] <https://www.moh.gov.sa/HealthAwareness/EducationalContent/wh/Breast-Cancer/Pages/default.aspx> .Retrieved 17/12/2020
- [2] S. Aruna, S.P.Rajagopalan 2011. **knowledge based analysis of various statical tools in detection breast cancer**.Computer Science and Information Technology.V.2.PP.37-45
- [3] Dina Ragab, Maha Sharkas 2013 ."**A comparison between support vector machine and artificial neural network for breast cancer detection 2 the cad system**".The 12th WSEAS International Conference on Signal.PP.171\_176.
- [4] Daniel levy,Arzav Jain 2016.**Breast mass classification using deep convolutional neural networks**. the 30th conference on neural information processing systems.Barcelona, Spain. PP.1\_6.
- [5] Teresa Araujo,Guilherme Aresta 2017.**Classification of breast cancer histology images using Convolutional Neural Networks**.Plos one journal.V.16.PP.1-14.

- [6] Arfan Jaffar 2017. **Deep Learning based Computer Aided Diagnosis System for Breast Mammograms.** International Journal of Advanced Computer Science and Applications.V.8,NO.7.
- [7] Prabhpeet kaur et al 2019.**Intellectual detection and validation of automated mammogram breast cancer images by multi-class SVM using deep learning classification,** Informatics in Medicine Unlocked journal, PP.1-19.
- [8] Dina Ragab et al 2019. **Breast cancer detection using deep convolutional neural networks and support vector machines.**Peer Journal.V.10.
- [9] Aditya Khamparia, Subrato Bharati 2020.**Diagnosis of Breast Cancer Based on Modern Mammography using Hybrid Transfer Learning.** Electrical Engineering and Systems Science.V.3,PP.1-24.

- [10]Kadir GUZEL,Gokhan BILGIN 2020,**Classification of Breast Cancer Images Using Ensembles of Transfer Learning**. Sakarya University Journal of Science.V.24.PP.791–802.
- [11]Li Shen, Laurie Margolies 2018, **“Deep Learning to Improve Breast Cancer Early Detection on Screening Mammography”**,Scientific Reports.V.9.
- [12]Oliver Diaz, Robert Marti 2018, **“ Mass detection in mammograms using pre-trained deep learning models”**,.14th International Workshop on Breast Imaging , V.10718, p. 12.
- [13]J.Sucklin 1996 .**The mammographic image analysis society digital mammogram database**.
- [14]Wenbin Yue, Zidong Wang 2018. **“Machine Learning with Applications in Breast Cancer Diagnosis and Prognosis”**,Designs journal, V.13,PP.1–17.
- [15]Aurelien Geron 2019.**“Hands–On Machine Learning with Scikit–Learn, Keras &TensorFlow”**, 2nd edition, O’Reilly Media.
- [16]Min Zhu,Jing Xia 2018.**“Class weights random forest algorithm for processing class imbalanced medical data”**,IEEE Access6,PP.4641–4652.
- [17]Yuanqin Chen,Qian Zhang 2019,**“Fine–tuning ResNet for breast cancer classification from mammography** .Proceedings of the 2nd International Conference on Healthcare Science and Engineering.PP. 83–96.
- [18]Lenin Falconi,Maria Perez 2019,**“Transfer Learning in Breast Mammogram Abnormalities Classification with Mobilenet and Nasnet”**. Technology and Engineering Systems Journal.V.5,No.2,PP.154-165 .

- [19]Nitish Srivastava, Geoffrey Hinton 2014,"**Dropout: A Simple Way to Prevent Neural Networks from Overfitting**", Journal of Machine Learning Research.V.15,PP.1929–1958.
- [20]Mariam M. Saii 2019.**Classification of Pattern Recognition Techniques Used Deep Learning and Machine Learning.**  
International Journal of Computer Science Trends and Technology .  
V.7 ،PP.165–173.
- [21]Sonika Nagar et al 2021." **A Convolutional Neural Network To Predict Breast Cancer For Histopathological Images**". Advances and Applications in Mathematical Sciences. V. 20, Issue 3, PP.409–426.

