دولة ليبيا

وزارة التعليم العالي والبحث العلمي

جامعة سبها

كليـة تقنيـة المعلومات

قســـم عـلـوم الـحـاسـب

بحث مقدم لاستكمال متطلبات نيل درجة البكالوريوس بكلية تقنية المعلومات

تحت عنوان:

تصنيف صور الأنسجة لسرطان الثدي باستخدام نموذج الشبكات العصبية الالتفافية Alexnet

Classification Of Breast Cancer Histology Images Using Convolutional Neural Network model Alexnet

إعداد الطالبة:

زهرة أدم جدة علوي

تحت إشراف:

أ. عائشة موسى الفيتوري

العام الجامعي

2022-2021

الإقرار

إقرار الطالب / الطلاب

أنا الطالبة: زهرة أدم جدة علوي **الرقم الدراسي:** 202170393

أقر / نقر بأن ما ورد في هذا البحث هو من مجهودي الشخصي ما عدا الفقرات التي تم إسنادها إلى مرجع.

التاريخ: ..... **التوقيع:** .....

إقرار المشرف

اسم المشرف: أ. عائشة موسى الفيتوري

أقر بأني اطلعت على مادة البحث، وأن هذا البحث جاهز للمناقشة.

التاريخ: ..... **التوقيع:**.....

إقرار بالموافقة على التصحيحات وتسليم النسخة النهائية:

بعد التصحيح والاطلاع على مادة هذا البحث، تمت الموافقة عليها، وتسليم النسخة النهائية.

اسم الممتحن الأول: .....**التوقيع:** .....**التاريخ:** .....

اسم الممتحن الثاني: .....**التوقيع:** .....**التاريخ:** .....

﴿بِسْمِ اللَّهِ الرَّحْمَٰنِ الرَّحِيمِ﴾

﴿قَالُوا سُبْحَانَكَ لَا عِلْمَ لَنَا إِلَّا مَا عَلَّمْتَنَا إِنَّكَ أَنتَ الْعَلِيمُ الْحَكِيمُ﴾

{سورة البقرة: الآية 32}

الإهداء

أهدي هذا العمل أولا إلى من أحمل اسمه وكلي اعتزاز . . إلى رفيق الخطوة الأولى . . والخطوة ما قبل الأخيرة . . إلى من كان في السنوات العجاف سحابا ممطرا . . أنا ممتنة جدا إلى . . **أبي**.

إلى جنتي في الدنيا وملاذي الآمن بهجة الحياة ومبسمها . . إلى من ربتني وعلمتني وكانت خير عون لي ومعين. . **أمي الغالية**.

إلى من أتقاسم معهم تفاصيل أيامي أجملها وأصعبها . . إلى سندي ومتكأي الثابت . . **إخوتي**.

رفقاء الدرب وأصدقائي الحاضرين . . إلى من صعدنا معا يدا بيد حتى نصل سويا لمبتغانا . . إلى رفقاء الطفولة الغائبين عن العين القريبين إلى القلب . . **أصدقائي الأعزاء**.

إلى من أنار الدرب ومهد طريق العلم . . إلى الذين لم يبخلوا في عطائهم وأجزلوا . . **أساتذتي الكرام**.

إلى أهلي وأحبائي . . إلى كل من ساعدني ودعمني لأكمل المشوار . . أهديكم هذا العمل وأسأل الله تعالى أن يكون علما نافعا ومتقبلا.

شكر وعرفان

الحمد لله حمدًا كثيراً طيباً مباركاً فيه، الحمد لله حتى يبلغ الحمد منتهاه، و صل اللهم وبارك على هادينا و معلمنا الخير نبينا محمد صل الله عليه وسلم و على أله وصحبه و التابعين له، من لا يشكر الناس لا يشكر الله، اعترافاً منا بالجميل توجب علينا توجيه خالص الشكر و العرفان إلى أصحاب الفضل بعد الله سبحانه و تعالى، إلى أستاذَي الفاضلَين الذَين ألهماني بالأفكار و وجها إلي النصح و أمداني بالمعلومات و التوجيهات لإتمام هذا البحث إلى مشرفتي الأستاذة عائشة موسى الفيتوري و الدكتور الفاضل حمودة شفتر، لهما مني كل الشكر و التقدير الامتنان، الشكر موجه إلى أعضاء هيئة التدريس و العاملين بكلية تقنية المعلومات جامعة سبها، إلى أمي الحبيبة و أبي الغالي، إلى أخوتي و أصدقائي و أهلي و أحبائي، إلى كل من ساعدني و مد لي يد العون و من كان له الفضل في إتمام هذا العمل و لو بالتشجيع و بالدعوات الخالصة.

لكم مني جميعا جزيل الشكر والعرفان.

فهرس المحتويات

فهرس الأشكال

فهرس الجداول

جدول المصطلحات

المصطلح باللغة العربية	المصطلح باللغة الإنجليزية	الإختصار
الذكاء الاصطناعي	Artificial Intelligence	AI
الشبكات العصبية الاصطناعية	Artificial Neural Networks	ANN
الشبكات العصبية العميقة	Deep Neural Networks	DNN
التعلم العميق	Deep Learning	DL
الشبكات العصبية الالتفافية	Convolution Neural Networks	CNN
سرطان الثدي	Breast Cancer	BC
صور الأنسجة	Histology Image	-
نموذج Alexnet	Alexnet Model	-
مجموعة بيانات Breakhis	Breakhis Dataset	-
فرط التخصيص	Overfitting	-
الزيادة الإفتراضية للبيانات	Data Augmentation	-
الإفراط في أخذ العينات	Oversampling	-
الإختزال في أخذ العينات	Undersampling	-
تنظيم الأوزان	Weight Regularization	-

الملخص Abstract

يعتبر سرطان الثدي من أكثر الأمراض انتشارا في العالم و هو مرض يصيب النساء بصورة كبيرة، أدى انتشاره في السنوات الأخيرة إلى زيادة معدلات الوفيات، و هناك احتمالية زيادة عدد الإصابات في السنوات القادمة، و نظرا لما يعانيه التشخيص البصري لهذه الأمراض من مشاكل منها الحصول على نتائج خاطئة و غير دقيقة، واستغراقه الكثير من الوقت و الجهد، فقد تم مؤخراً الاستعانة بالتقنيات الحديثة و بالتحديد تقنيات التعلم العميق في تحليل و تصنيف هذه الأمراض وذلك لمساعدة الأطباء في الاكتشاف المبكر و الدقيق للأمراض، في هذا البحث تم استخدام نموذج Alexnet و هو أحد نماذج الشبكات العصبية الالتفافية التي تندرج تحت مصطلح التعلم العميق، تم تدريب النموذج على مجموعة بيانات Breakhis التي تحتوي على مجموعة متنوعة من صور الأنسجة للأورام الحميدة و الخبيثة للثدي، النتائج النهائية التي تم الحصول عليها بعد تحسين النموذج باستخدام التقنيات Data Augmentation و Oversampling و Weight Regularization كانت كالتالي: حقق النموذج نسبة دقة تصل إلى 94% لمجموعة البيانات (×40) و (×100) و (×400)، و 93% لمجموعة البيانات (×200).

الفصل الأول

المقدمة

1. المقدمة Introduction

يعتبر سرطان الثدي Breast Cancer (BC) من أكثر الأمراض انتشارا في العالم، و هو مرض يصيب النساء بصورة كبيرة، ينشأ السرطان عندما تبدأ خلايا الجسم الغير طبيعية بالانفصال والتلامس مع الخلايا الطبيعية و جعلها خبيثة، جزء الجسم الذي يحتوي على سرطان الثدي هو الغدد و قنوات الحليب، ازدادت معدلات الوفيات في السنوات الأخيرة بسبب سرطان الثدي حيث حدثت حوالي 9,6 مليون حالة وفاة في عام 2018 كما ذكرت منظمة الصحة العالمية، تشير الإحصائيات التي أجرتها المنظمة إلى أن عدد مرضى سرطان الثدي سيزداد بنسبة 70% في العقدين المقبلين[5].

توجد العديد من الاختبارات التشخيصية لسرطان الثدي التي يتم إجراؤها للتأكد ما إذا كان الشخص مصاب بورم حميد أو خبيث، مثل التصوير بالأشعة السينية و التصوير بالرنين المغناطيسي و تحليل صور الأنسجة و غيرها، و تعرف صور الأنسجة Histology Images بأنها الصور التي يتم التقاطها بالمجهر لعينة نسيج الورم التي يتم أخذها من جسم المريض ، يؤدي التشخيص البصري لهذه الأورام السرطانية أحيانا إلى الحصول على نتائج خاطئة أو غير دقيقة و ذلك نتيجة الأخطاء البشرية الناجمة عن القصور و المشاكل البصرية، تعتبر مهمة اكتشاف و تحديد الإصابة بالسرطان مهمة صعبة و تستغرق الكثير من الوقت و يؤديها اختصاصي الأشعة ذوي الخبرة و الأطباء المختصين، حيث تعتمد دقة التشخيص على خبرة الطبيب فقط لذلك أصبح استخدام تكنولوجيا المعلومات ضروري للتغلب على هذه القيود و التي تساعد الأطباء في اكتشاف و تشخيص سرطان الثدي[5].

مؤخرا ركزت العديد من الدراسات على استخدام تقنيات التعليم العميق Deep Learning (DL) و الذي يعرف أيضا باسم الشبكات العصبية العميقة Deep Neural Network (DNN) في تشخيص الأمراض، حيث يمكن تعريف التعلم العميق بأنه الطريقة التي تمكن الكمبيوتر من تعلم و محاكاة طريقة تفكير البشر القائمة على التدريب و اكتساب الخبرة في التعرف على الاشياء و اتخاذ القرارات بنفس الطريقة التي يفهم بها الدماغ، تعتبر الشبكات العصبية الملتفة Convolutional Neural Network (CNN) أحد اشهر أنواع الشبكات العصبية العميقة المستخدمة في تصنيف الصور حيث استخدمت بشكل كبير في المجالات الطبية لتشخيص الأمراض و كذلك استخدمت في التعرف على الأشياء مثل التعرف على الوجوه و الطعام و تحليل الفيديوهات وغيرها.

يهدف هذا البحث إلى تصنيف صور الأنسجة لسرطان الثدي باستخدام نموذج الشبكات العصبية الملتفة Alexnet، تم تدريب النموذج على تصنيف الأورام الحميدة و الخبيثة باستخدام مجموعة بيانات BreakHis، و مراقبة النتائج المتحصل عليها لمعرفة العوامل التي تؤثر على دقته في إعطاء النتائج، و بناء على وجود هذه العوامل تم تحسين قدرته على التصنيف.

1.1 مشكلة البحث Research Problem

يؤدي التشخيص البصري للخلايا السرطانية إلى حصول على نتائج خاطئة أو غير دقيقة لحجم و موقع الخلايا و ذلك نتيجة الأخطاء البشرية الناجمة عن القصور و المشاكل البصرية، حيث تعتبر مهمة اكتشاف و تحديد الإصابة بالسرطان مهمة صعبة و تستغرق الكثير من الوقت الجهد و تعتمد دقة التشخيص على خبرة الطبيب فقط، المشكلة الرئيسية في الكشف عن سرطان الثدي تتلخص في الآتي:

1. قلة استخدام التقنيات الحديثة في تشخيص سرطان الثدي محليا.

2. تأثر نماذج الشبكات العصبية الالتفافية بمجموعة من العوامل مثل حجم البيانات المستخدمة و عدم توازن خصائصها و غيرها من العوامل.

2.1 أسئلة البحث Research Questions

بالنظر إلى مشكلة البحث تم وضع مجموعة التساؤلات التالية لحلها:

1. هل استخدام نموذج الشبكات العصبية الملتفة Alexnet سيؤدي إلى حصول على نتائج بنسبة دقة عالية؟

2. ما هي العوامل التي تؤثر على أداء النموذج المقترح ؟

3.1 أهداف البحث Research Objectives

من خلال الأسئلة السابقة يهدف البحث إلى تحقيق الآتي:

1. تصنيف صور الأنسجة لسرطان الثدي باستخدام نموذج الشبكات العصبية الملتفة Alexnet.

2. تحسين النموذج المستخدم من خلال دراسة العوامل التي تؤثر على نسبة دقته.

4.1 أهمية البحث Significance of the Research

يحتاج الأطباء إلى طرق جديدة و متطورة لمساعدتهم في الكشف المبكر عن الأمراض و تقليل احتمالية انتشار المرض و تدهور صحة المريض، إن استخدام نموذج الشبكات العصبية الملتفة المقترح سيؤدي إلى الحصول على نتائج أكثر دقة في الكشف عن سرطان الثدي و مساعدة الأطباء في التشخيص المبكر و بالتالي تجنب أخطاء التشخيص الناجمة عن القصور و الأخطاء البشرية، سيتم تقديم النموذج المقترح و ما تم التوصل إليه من نتائج إلى مركز الأورام بسبها لمساعدة الأطباء في الحصول على نتائج تشخيص دقيقة و بنسبة موثوقية عالية، و من خلال العوامل التي تم دراستها و الخطوات التحسينية التي تم تطبقها في هذا البحث يمكن للباحثين في هذا المجال الاعتماد عليها في تجاربهم المستقبلية.

5.1 حدود البحث Research Scope

سيتم التركيز في هذا البحث على استخدام أحد نماذج الشبكات العصبية الالتفافية في تصنيف صور الانسجة لسرطان الثدي، تم بالتحديد استخدام نموذج Alexnet في التصنيف الثنائي لصور انسجة سرطان الثدي المأخوذة من مجموعة بيانات BreakHis.

6.1 منهجية البحث Research methodology

تعد منهجية البحث أحد أهم أجزاء البحث العلمي، و هي عبارة عن مجموعة من الخطوات التي يقوم بها الباحث في دراسته، بمعنى آخر هي الخطوات التي يجب أن يسير عليها الباحث أثناء قيامه بالبحث العلمي و التي من خلالها سيجد الحل المناسب للمشكلة، يتبع هذا البحث الخطوات الأساسية المتبعة في الدراسات ذات الصلة و التي قامت باستخدام النماذج المختلفة للشبكات العصبية الاصطناعية في تصنيف الأمراض، تتبع جميع هذه الدراسات نفس الخطوات الأساسية المتمثلة في: (تحميل مجموعة البيانات، المعالجة المسبقة، تقسيم مجموعة البيانات، تدريب النموذج، تقييم النموذج) مع وجود بعض الاختلافات نظرا لاختلاف مشكلة و هدف كل بحث[7،6].

الشكل التالي يوضح الخطوات الأساسية للمنهجية المتبعة في الدراسات ذات الصلة:

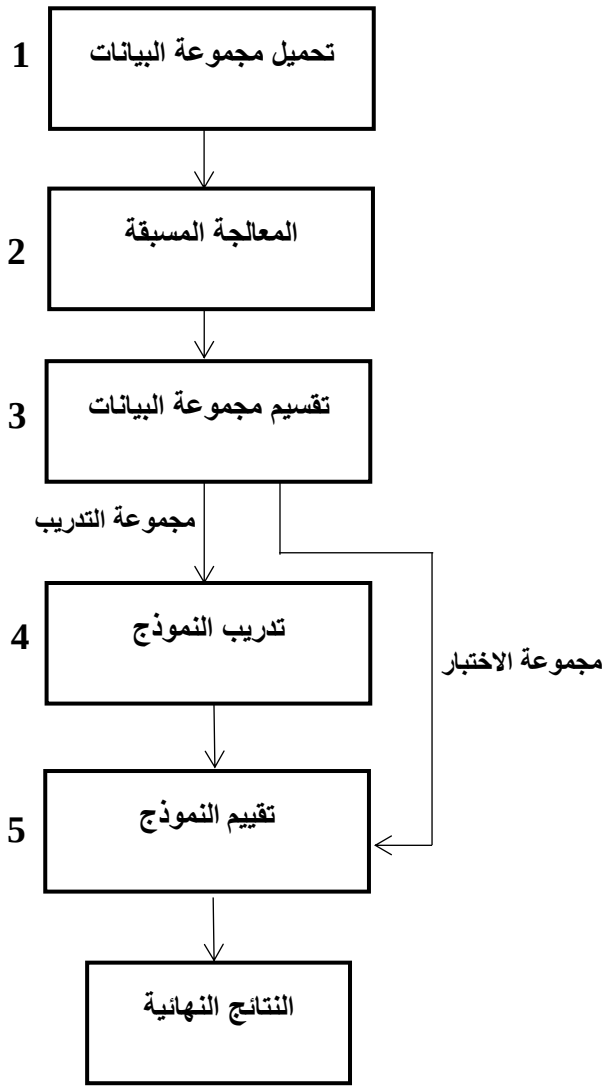

الشكل (1.1) يوضح المنهجية المتبعة في الدراسات ذات الصلة

في هذا البحث سيتم إتباع جميع الخطوات الأساسية للمنهجية المتبعة في الدراسات السابقة، مع إضافة بعض الخطوات للمنهجية للتوافق مع الخطوات الفعلية التي تم اتباعها، و تتمثل الخطوات التي تمت إضافتها في خطوة تحسين النموذج.

الشكل التالي يوضح خطوات المنهجية التي تم إتباعها في هذا البحث:

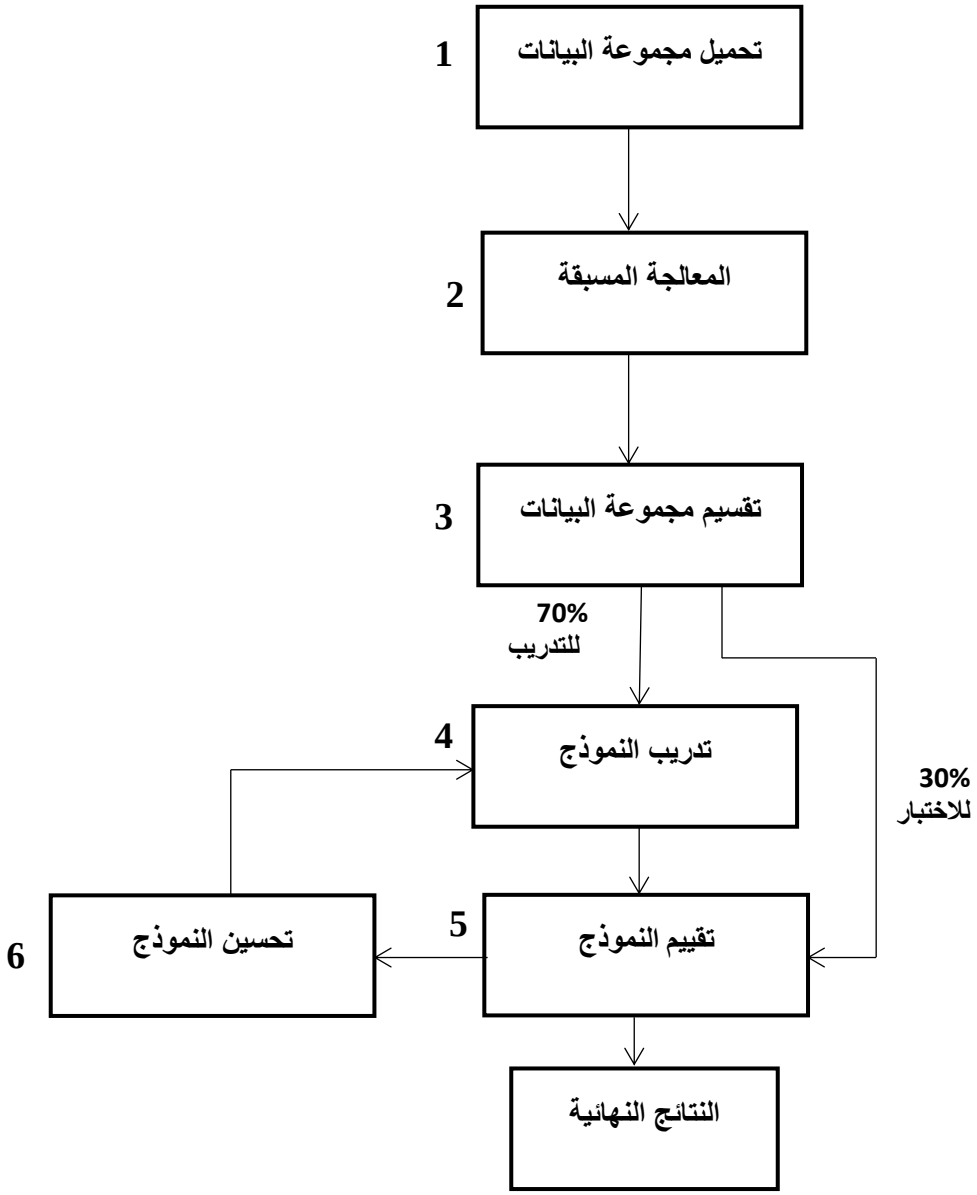

الشكل (2.1) يوضح منهجية البحث

1. تحميل مجموعة البيانات: في هذه الخطوة يتم تحميل مجموعة البيانات بعد البحث عن مجموعة البيانات المناسبة و المتعلقة بموضوع الدراسة و التأكد من سلامتها وذلك من خلال الاطلاع على المعلومات المرفقة في الوصف الرسمي لها، و الذي يحتوي على تفاصيل عن مجموعة البيانات مثل نوع الصور و حجمها و عددها و الطرق التي تمت بها عملية تجميع العينات و تصنيفها و معرفة

الفئات التي تحتويها، في هذا البحث تم تحميل صور الأنسجة لسرطان الثدي من مجموعة البيانات Breakhis.

2. المعالجة المسبقة: تتمثل خطوة المعالجة المسبقة في إجراء مجموعة من العمليات على البيانات التي تم تحميلها قبل إدخالها للنموذج، كتغير حجمها أو تحويلها إلى صيغة مختلفة و غيرها من العمليات التي يتم إجرائها و فقا لما تتطلبه كل دراسة، في هذا البحث لم يتم إجراء أي عملية تعديل على محتوى الصورة و لكن سيتم إجراء بعض العمليات التي تتطلبها عملية التدريب، مجموعة البيانات التي يتم تحميلها تكون عادة غير مرتبة و توزع البيانات فيها في ملفات متفرقة و غير مقسمة بطريقة تكون جاهزة للاستخدام، بالتالي يتعين إعادة ترتيبها و تقسيمها في ملفات حسب المهمة التي ستجرى عليها، في هذه البحث تتكون مجوعة البيانات التي تم تحميلها من فئتين، فئة تمثل صور الأورام الحميدة و فئة الأورام الخبيثة و كل فئة تحتوي على أربعة أنواع من الأورام و لأنه سيتم تدريب النموذج على التصنيف الثنائي سيتم دمج الأنواع الأربعة من كل فئة في ملف واحد، وتتمثل الخطوة الثانية في تقليل حجم الصور في مجموعة البيانات لكي تتناسب مع الحجم الذي يتطلبه النموذج المستخدم

3. تقسيم مجموعة البيانات: بعد ترتيب مجموعة البيانات و توزيعها في ملفات يتم تقسيمها إلى مجموعتين، مجموعة لتدريب النموذج و مجموعة لاختباره، أولا تم تقسيم مجموعة البيانات إلى 70% لمجموعة التدريب و 30% لمجموعة الاختبار، و من ثم تم تغييرها في مرحلة من مراحل التدريب إلى 80% لمجموعة التدريب و 20% لمجموعة الاختبار.

4. تدريب النموذج: في هذه المرحلة يتم تمرير مجموعة بيانات التدريب للنموذج مع تحديد الفئة التي تنتمي لها كل عينة ليتعلم و يتدرب عليها في هذا البحث تم استخدام نموذج Alexnet، يقوم النموذج في الطبقات الأولى باستخراج السمات المهمة من كل صورة و من ثم يتم تمريرها إلى طبقة كاملة الاتصال ليتم من خلالها التمييز بين السمات المختلفة لكل فئة، تم تدريب النموذج على مجموعة بيانات التدريب عدة مرات لتحسين أداءه.

5. تقييم النموذج: بعد تدريب النموذج يتم تقييم أدائه باستخدام مجموعة من المقاييس، أولا يتم تقييمه من خلال قدرته على التعلم من مجموعة بيانات التدريب بعد كل مرحلة تدريب و ذلك باستخدام

المقياسيين: (train_accuracy, train_loss)، و يتم قياس مدى قدرته في تصنيف الصور الجديدة و التي لم يتدرب عليها من قبل باستخدام مجموعة بيانات الاختبار و ذلك من خلال المقياسيين: (val_ accuracy , val_loss)، وبعد الانتهاء من تدريب واختبار النموذج عدة مرات يتم استخدام المقاييس التالية: (Precision, Recall, Accuracy, F1-score) و ذلك لتقييم أداءه من عدة جوانب.

6. تحسين النموذج: بعد تدريب واختبار النموذج عدة مرات و تقييم مدى دقته في إعطاء النتائج يتم من خلال مقاييس التقييم دراسة العوامل و المتغيرات التي أثرت على دقته، و من خلال هذه العوامل يتم اقتراح الحلول التي من شأنها تحسين أداء النموذج و يتم تطبيقها و إعادة تدريب النموذج من جديد و تقييمه و دراسة مدى تأثير الحلول المقترحة على النتائج.

7.1 تنسيق البحث Research format

الفصل الأول: يحتوي على المفاهيم الأساسية للبحث حيث يشمل المقدمة و مشكلة البحث و أهداف البحث و حدوده و المنهجية المتبعة لتحقيق الأهداف المرجوة من البحث.

الفصل الثاني: يشمل الفصل الثاني الإطار النظري للبحث والذي يتضمن التعريف بمرض سرطان الثدي و أنواعه و طرق تشخيصه، و يشمل أيضا الشبكات العصبية الاصطناعية بشكل عام و آليتها و طرق تعليمها ، و من ثم تم التطرق إلى الشبكات العصبية الالتفافية بشكل خاص و كذلك الدراسات السابقة المتعلقة بموضوع البحث و النظام المقترح و توضيح أوجه الشبه و الاختلاف بينهما.

الفصل الثالث: يتضمن هذا الفصل منهجية البحث بشكل مفصل حيث تم توضيح الخطوات التي تم إتباعها في البحث و التحدث عن كل خطوة بالتفصيل، و يحتوي أيضا على منصات العمل والمكتبات والأدوات المستخدمة في البحث.

الفصل الرابع: يحتوي على النتائج التي تم التوصل إليها بعد تنفيذ النموذج و مناقشة هذه النتائج.

الفصل الخامس: يوضح الفصل الأخير الصعوبات والتحديات التي واجهت البحث والتوصيات و الخاتمة.

الفصل الثانـي

الإطار النظري و الدراسات السابقة

2. المقدمة

يحتوي هذا الفصل على الإطار النظري و الذي سيتم فيه الشرح بشكل عام عن سرطان الثدي وأنواعه و مضاعفات، و كذلك يشمل التعريف عن الشبكات العصبية الاصطناعية و آلية عملها وطرق تعليمها، و من ثم الشرح بشكل مفصل عن الشبكات العصبية المستخدمة في هذا البحث و هي الشبكات العصبية الالتفافية و الشرح عن كل طبقة من طبقاتها و كيفية عملها، و يتناول أيضا الدراسات السابقة التي لها علاقة بموضوع البحث و الدراسة المقترحة و شرح أوجه الشبه و الاختلاف بينها.

1.2 سرطان الثدي Breast Cancer

"يعرف سرطان الثدي بأنه نمو غير طبيعي للخلايا المبطنة لقنوات الحليب أو فصوص الثدي و سرطان الثدي أحد الأورام الخبيثة الشائعة، و غالبا ما يتكون الورم في قنوات نقل الحليب و أحيانا في الفصوص و جزء بسيط من بقية الأنسجة"[4].

1.1.2 الأنواع

ينقسم سرطان الثدي إلى نوعين من الأورام وهي:

- **الأورام الحميدة Benign Tumors**

"تعرف بأنها نمو غير طبيعي للخلايا الغير سرطانية أي أنها لا تغزو أو تتشر إلى الخلايا المحيطة بها، بل تبقى و تكبر في نفس المكان الذي نشأت فيه، و تنمو الأورام الحميدة بشكل بطيء و لا تعود مرة أخرى بعد إزالتها"[22].

من أنواع الأورام الحميدة: الورم الأنبوبي Tubular Adenoma، والورم الورقي Phyllodes Tumor، و ورم الغدد الليفية Fibroadenoma، وورم الغدد Adenosis Tumor.

- **الأورام الخبيثة Malignant Tumors**

"تعرف بأنها أورام سرطانية تنمو خلاياها بشكل سريع و خارج عن السيطرة، و تختلف الأورام الخبيثة عن الحميدة بقدرتها على الانتقال و الانتشار من العضو المصاب أي من مكان منشأها إلى أي

عضو آخر في الجسم عن طريق الدم أو الليمف، من الممكن أن تعود الأورام الخبيثة مرة أخرى بعد العلاج في العضو نفسه أو في عضو آخر"[22].

من أنواع الأورام الخبيثة: السرطان الحليمي Papillary Carcinoma، و السرطان المخاطي Mucinous Carcinoma، و السرطان الفصيصي Lobular Carcinoma، و سرطان الأقنية Ductal Carcinoma.

2.1.2 طرق التشخيص

تتضمن الاختبارات والإجراءات المستخدمة لتشخيص سرطان الثدي ما يلي:

- **فحص الثدي:** يتم إجراء الفحص الإكلينيكي من قبل الطبيب للثدي والعقد اللمفاوية أسفل الإبط و يتحسس لتحري وجود أي تكتلات أو أي أمور أخرى غير طبيعية.

- **التصوير الشعاعي (الماموغرام):** هو تصوير الثدي بالأشعة السينية، و ذلك في حالة اكتشاف وجود أمور غير طبيعية في الفحص.

- **الأشعة بالموجات فوق الصوتية:** تستخدم الموجات فوق الصوتية للحصول على صور لبنى موجودة عميقا داخل الجسم، و لتحديد ما إذا كان انتفاخ الثدي الجديد على هيئة كتلة صلبة أو تكيس ممتلئ بالسائل.

- **استخراج عينة من خلايا الثدي (خزعة):** الخزعة هي الطريقة القطعية الوحيدة لتشخيص سرطان الثدي، أثناء إجراء الخزعة يستخدم جهاز بإبرة مخصوصة، يتم توجيهه بالأشعة السينية، أو أي اختبار تصوير آخر لاستخراج مجموعة من الأنسجة من المنطقة المشتبه في إصابتها، يتم إرسال عينات الخزعة إلى المعمل لتحليلها حيث يحدد الخبراء ما إذا كانت الخلايا سرطانية أم لا، كما يتم أيضا تحليل عينة الخزعة لتحديد نوع الخلايا الموجودة في سرطان الثدي، و مدى خطورة (درجة) السرطان، و ما إذا كانت الخلايا السرطانية تحتوي على مستقبلات هرمونية أو مستقبلات أخرى يمكنها أن تؤثر على العلاج.

- **تصوير الثدي بالرنين المغناطيسي (MRI):** يستخدم جهاز التصوير بالرنين المغناطيسي موجات

مغناطيسية و راديوية، لإنشاء صور من داخل الثدي و على عكس الأنواع الأخرى من اختبارات التصوير، يستخدم MRI الإشعاع لإنشاء الصور[23].

2.2 صور الانسجة Histology Image

علم الأنسجة هو دراسة التركيب المجهري لخلايا و أنسجة الكائنات الحية، يقوم المختصين بأخذ عينة من المصاب و من ثم فحص الأنسجة تحت شريحة مجهرية و مراقبتها لتحديد الخصائص الحيوية التي تشير إلى وجود المرض مثل السرطان و غيره من الأمراض، يتطلب تقييم نتائج الصور التي تم الحصول عليها إلي دقة كبيرة حيث تأخذ العملية الكثير من الوقت، و من هنا ظهرت الحاجة إلي تطوير أنظمة بمساعدة الكمبيوتر للمساعدة في التشخيص و تقليل الأخطاء الذاتية و المشاكل التي تواجه المختصين في هذا المجال و مساعدتهم على اتخاذ القرار، يتم الحصول على صور التشريح المرضي باستخدام كاميرات متخصصة و يتم استخدام المجهر و ضبطه على مستويات محددة من معاملات التكبير و على مناطق معينة يتم تحديدها من قبل المختصين لدراسة التركيبات الحيوية المختلفة و مكونات الأنسجة تحت المجهر، يمكن اكتشاف و تشخيص الأورام السرطانية باستخدام العديد من طرق التصور الطبي مثل التصوير بالرنين المغنطيسي و التصوير بالموجات فوق الصوتية، و مع ذلك فإن أخذ الخزعة من المريض تعتبر الطريقة الوحيدة للتشخيص التي يتم عن طريقها تحديد نوع الورم إذا كان السرطان موجودا بالفعل، و بالتالي فإن التشخيص باستخدام صور التشريح المرضي تعتبر الطريقة الأمثل في تشخيص جميع أنواع السرطان [9،8].

3.2 الذكاء الاصطناعي في الطب

"الذكاء الاصطناعي Artificial Intelligence (AI) هو أحد مجالات علوم الكمبيوتر الذي يساعد في تطوير الأجهزة التي تحاكي تفكير الإنسان في معالجة البيانات و القدرة على التصحيح الذاتي، يستخدم مصطلح الذكاء الاصطناعي للأنظمة التي تنفذ المهام التي تتطلب تدخلا بشريا حيث يمكن لهذه الانظمة تنفيذ مهام مثل اتخاذ القرار و الإدراك البصري و التعرف على الكلام و ترجمة اللغات، و يمكن تعريفه أيضا على أنه شبكة تكرر بنية و وظيفة الذكاء البشري، يتزايد دور تقنيات الذكاء الاصطناعي في إجراءات التشخيص حيث تساعد في المجال الطبي لتشخيص الأمراض من خلال

العلامات و الأعراض السريرية و كذلك الصور الإشعاعية للمريض، تساهم هذه التقنيات الأطباء في معالجة المشكلات المعقدة و التي تتطلب الكثير من الوقت" [6].

4.2 الشبكات العصبية الاصطناعية Artificial Neural Networks (ANN)

"الشبكة العصبية الاصطناعية هي محاولة لمحاكاة شبكة من الخلايا العصبية التي تشكل دماغ الأنسان حتى تتمكن أجهزة الكمبيوتر من التعلم و اتخاذ القرارات بطرق بشرية"[1].

وتعرف أيضا بأنها "تقنيات حسابية مصممة لمحاكاة الطريقة التي يؤدي بها الدماغ البشري مهمة معينة، وذلك عن طريق معالجة ضخمة موزعة على التوازي، و مكونة من وحدات معالجة بسيطة، هذه الوحدات ما هي إلا عناصر حسابية تسمى عصبونات أو عقد (Nodes , Neurons) و التي لها خاصية عصبية، من حيث أنها تقوم بتخزين المعرفة العملية و المعلومات التجريبية لتجعلها متاحة للمستخدم و ذلك عن طريق ضبط الأوزان" [2].

1.4.2 آلية عمل الشبكات العصبية الاصطناعية

تتكون الشبكات العصبية الاصطناعية من مجموعة طبقات من العقد، تتمثل في طبقة الإدخال و طبقة مخفية واحدة أو أكثر و طبقة إخراج، بمجرد تحديد طبقة المدخلات يتم تخصيص أوزان weight أولية لكل عقدة و يتم تحديثها في كل مرة يتم فيها تدريب الشبكة، تساعد هذه الأوزان في تحديد أهمية أي متغير تم تحديده، حيث يكون للكبير منها مساهمة أكبر في المخرجات مقارنة بالمدخلات الأخرى، يتم ضرب كل المدخلات بعد ذلك في أوزان كل منها ثم يتم جمعها، بعد ذلك يتم تمرير المخرجات من خلال دالة التفعيل التي تقوم بتحديد المخرجات، إذا كانت المخرجات تتجاوز حد معين فإنها تقوم بتفعيل العقدة، و ذلك بتمرير البيانات إلى الطبقة التالية في شبكة الاتصال نتيجة لذلك تصبح المخرجات الخاصة بعقده ما متواجدة في مدخلات العقدة التالية، عملية تمرير البيانات من طبقة إلى الطبقة التالية تسمى بالتغذية الأمامية forward−Propagation [3].

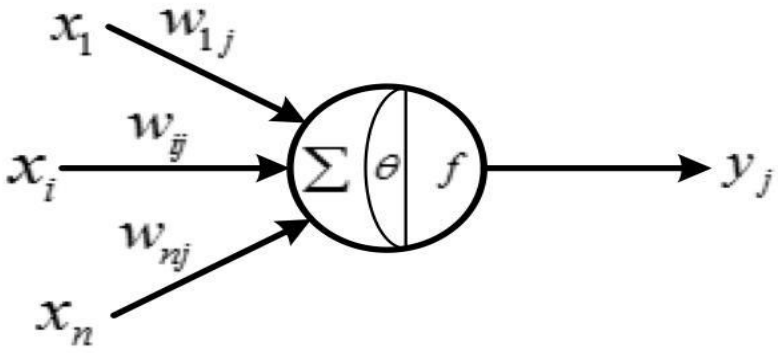

شكل (1.2) يوضح بنية العقدة في الشبكات العصبية [2]

يشير الرمز x_1 إلى مدخلات العصبون الاول، والرمز w_{1j} إلى وزن الخلية العصبية رقم 1 إلى الخلية العصبية j ، والرمز θ يشير إلى العتبة (الحد) للخلية العصبية، و الرمز f يشير إلى وظيفة التنشيط المستخدمة، يتم تمثيل العقد في الشبكات العصبية بالمعادلة الرياضية التالية:

$$y_j = f(\sum_{i=1}^{n} x_n w_n + b)$$

أولا يتم ضرب كل مدخل x بالوزن w و من ثم يتم جمع كل المدخلات الموزونة مع بعضها وإضافة انحياز (Bias) لها حيث يستخدم معامل الانحياز لتحديد ما هي أعلى قيمة للمجموع الموزون قبل أن يتم تفعيل العصبون، و أخيرا يتم تمرير الناتج إلى دالة التفعيل والتي تسمى أيضا بدالة التنشيط Activation Function، الهدف من دالة التنشيط هو تحويل مدخل غير مقيد إلى مخرج مقيد في نطاق معين، حيث أنه لن يتم تفعيل العصبون إذا كان الناتج أقل من 0 و يتم تفعيله إذا كان أكبر.

يتم تحديث قيمة الأوزن لتقليل قيمة الخسارة (الخطأ) الناتج في طبقة الإخراج، و ذلك من خلال عملية الانتشار الخلفي Back−Propagation، لحساب الخطأ يتم مقارنة القيمة المتوقعة مع قيمة المخرجات الفعلية، يتم استخدام دالة الخسارة لحساب قيمة الخطأ ثم يتم حساب مشتق قيمة الخطأ فيما يتعلق بكل وزن في الشبكة العصبية، يتم استخدام قاعدة السلسلة في حساب التفاضل، في قاعدة السلسلة يتم حساب مشتقات قيمة الخطأ فيما يتعلق بقيم الوزن للطبقة الأخيرة تسمى هذه المشتقات بالتدرجات و تستخدم قيم التدرج لحساب تدرجات الطبقة الثانية الأخيرة، تكرر هذه العملية حتى يتم

الحصول على التدرجات لكل وزن في الشبكة ثم تطرح قيمة التدرج من قيمة الوزن لتقليل قيمة الخطأ [6،2].

2.4.2 طرق تعليم الشبكات العصبية الاصطناعية

توجد أكثر من طريقة لتعليم الشبكات العصبية الاصطناعية [1]، وهي كالتالي:

- **التعليم الخاضع للإشراف** Supervised learning: يسمى أيضا بالتعليم بواسطة معلم تقوم الشبكات بالتعرف على أنماط البيانات المختلفة سواء كانت بيانات نصية أو صور و من ثم مقارنة نتيجة المعالجة لهذه البيانات مع النتائج الحقيقة من خلال عملية عكسية تتجه فيها البيانات بطريقة عكسية من طبقات الإخراج إلى طبقات الإدخال، تقوم بعدها الشبكات بتصحيح هذه الأخطاء للوصول إلى النتيجة المرجوة، يتم في هذه الطريقة إعطاء الشبكة مجموعة من البيانات للتعرف عليها و اكتشاف الأنماط التي تربطها و من ثم مقارنة النتائج التي توصلت إليها مع النتائج الحقيقة و تعديل قيمة الخطأ.

- **التعليم الغير خاضع للإشراف** Unsupervised learning: يتم استخدام هذا الأسلوب من التعلم عند معالجة بيانات التي لا توجد معلومات سابقة عن نتيجتها، فتقوم الشبكة بتحليل المعطيات و بناء دالة لتحديد درجة الخطأ و تقليلها بأقل نسبة ممكنة بهدف الوصول إلى أعلى الدرجات من الدقة الممكنة في هذه الطريقة تكون فئة التدريب عبارة عن مجموعة من المدخلات فقط دون عرض نتيجة البيانات الحقيقة على الشبكة، و تسمى هذه الطريقة أيضا باسم التعليم الذاتي حيث تبني الشبكات العصبية أساليب التعليم على أساس قدرتها على اكتشاف الصفات المميزة لما يعرض عليها من بيانات و قدرتها على تطوير تمثيل داخلي لهذه الأشكال و ذلك دون معرفة مسبقة و بدون عرض أمثلة لما يجب عليها أن تنتجه على عكس المبدأ المتبع في أسلوب التعليم بواسطة معلم.

- **التعليم المعزز** Reinforcement Learning: يعتمد نمط التعلم هذا على الملاحظة بشكل رئيسي، حيث تتم معالجة المعلومات والتوصل للنتائج التي تقدرها الشبكة العصبية، فإذا كانت إيجابية تعالج في كل مرة بنفس الطريقة، أما إن كانت سلبية تقوم الشبكة في المرة القادمة بمعالجتها بطرق مختلفة للوصول إلى نتيجة إيجابية.

5.2 الشبكات العصبية الالتفافية Convolutional Neural Networks

تعد الشبكة العصبية الالتفافية Convolutional Neural Network (CNN) أحد أنواع الشبكات العصبية العميقة Deep Neural Network حيث تستخدم في تطبيقات الرؤية الحاسوبية Computer Vision و تحليل المشاهد المرئية، إذ تتميز بوجود طبقة مخفية واحدة أو أكثر، من شأنها استخراج السمات الموجودة في النصوص أو الصور أو مقاطع الفيديو، و تحتوي أيضا على طبقة كاملة الارتباط لإنتاج الخرج المطلوب، هذه الشبكات مستلهمة بيولوجيا من القشرة البصرية Visual Cortex الموجودة لدى الإنسان و التي تحتوي على مناطق صغيرة من الخلايا تسمى بالخلايا العصبية أو العصبونات Neurons حساسة لمناطق معينة من المجال البصري، ترتبط كل خلية عصبية في طبقة من طبقات الشبكة بجميع الخلايا العصبية في الطبقة التي تليها، تتكون CNN من مجموعة من الطبقات Layers حيث يتم تمرير البيانات عبر هذه الطبقات بالتوالي مبتدئة بالطبقة الالتفافية Convolutional Layer و من ثم يتم تطبيق دالة التفعيل Activation Function بعدها طبقة التجميع Pooling Layer و منتهية بطبقة الارتباط الكامل Fully-Connected Layer، توجد العديد من النماذج التي يتم إنشاءها بناء على هذه الطبقات حيث تختلف في عدد الطبقات و ترتيبها وطرق الاتصال المستخدمة فيها[10].

1.5.2 الطبقة الالتفافية Convolutional Layer

عند استخدام الشبكات العصبية الالتفافية في تصنيف الصور فإن المدخلات إلى الشبكة هي عبارة عن صور يتم تمثيلها على هيئة مصفوفة ثلاثية الأبعاد (العرض × الارتفاع × العمق) من قيم تتراوح بين 0−255 متمثلة في نقاط لونية pixels متوزعة طولا و عرضا و ثلاث قنوات لونية (الأحمر والأخضر و الأزرق) إذا كان النظام اللوني للصور هو (RGB).

تعتبر الطبقة الالتفافية هي الطبقة الأولى من طبقات الشبكات العصبية الالتفافية يتم فيها استخدام مجموعة من المرشحات Filters تعرف أيضا باسم Kernels من شأنها تحديد وجود سمات Features أو أنماط معينة في الصورة المدخلة، حيث يتم استخدام مجموعة متنوعة من المرشحات لاستخراج سمات مختلفة، يكون المرشح ذا حجم صغير ليمسح الصورة بشكل كامل من اليسار إلى اليمين و من الأعلى إلى الأسفل، و يكون عمقه مساويا لعمق الصور المدخلة، بحيث يكون عمقه

واحد إذا كانت الصور المراد تطبيقه عليها هي صور غير ملونة أي تحتوي على لونين فقط هما الأبيض و الأسود، و يكون عمقه ثلاث قنوات لونية إذا كانت الصور ملونة، تطبق العمليات الحسابية المناسبة بين قيم المرشح و الصورة بغية استخراج السمات المهمة من كل صورة، مخرجات هذه الطبقة هي عبارة عن مجموعة من الصور كل منها يحتوي على سمات و تفاصيل مختلفة عن الصور الأخرى تسمى هذه الصور بخريطة السمات Features Map أو خريطة المعالم حيث يتم تمريرها إلى الطبقة التالية، يتم استخدام أكثر من طبقة التفافية في الشبكة حيث توظف الطبقات الأولى في استخراج السمات البسيطة و الواضحة مثل الحواف في الاتجاهات المختلفة، و مع التعمق أكثر في الطبقات تزداد درجة تعقيد السمات التي يتم تحديدها و استخراجها، في البداية يتم اختيار المرشحات بشكل عشوائي ومن ثم يتعلم النموذج اثناء عملية التدريب ليختار في النهاية أفضل المرشحات التي تعطي أفضل النتائج.

تتم عملية استخراج السمات المهمة من الصور باستخدام المرشح عن طريق ضرب كل قيمة من قيم المرشح بالقيم المقابلة لجزء الصورة المدخلة التي يتم تطبيقه عليها و يتم جمع هذه القيم و تستبدل القيمة المركزية به .

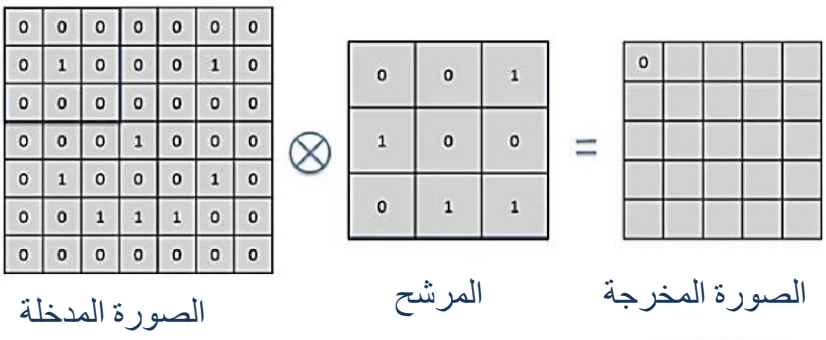

شكل (2.2) يوضح استخراج السمات باستخدام المرشح [7]

في مثال الصورة أعلاه يمكن حساب الناتج عند تطبيق المرشح على جزء من الصورة كالتالي:

(1 *0 + 0 * 1 + 0 * 0 + 0 * 0 + 0 * 1 + 1 * 0 + 0 * 1 + 0 * 0)= 0،

إذا كان الناتج من عملية تطبيق المرشح على جزء من الصور أقل من أو يساوي 0 فهذا يعني أن

السمة التي يبحث عنها المرشح غير موجودة في هذا الجزء، و يتفاوت تركيز وجود السمة في الصورة حسب القيمة الموجبة التي يتم الحصول عليها.

و يمكن ايضا حساب حجم الصورة التي تنتج عند تطبيق المرشح عن طريق تطبيق القانون التالي: (N-F+1* N-F+1) حيث N تمثل حجم الصورة و F تمثل حجم المرشح المستخدم، في مثال الصورة أعلاه لدينا صورة مدخلة بحجم 7×7 و مرشح بحجم 3×3 و عند تطبيق المرشح على الصورة يتم الحصول على صورة مخرجة بحجم 5×5، و يمكن حساب حجم الصورة المخرجة باستخدام القانون السابق كالتالي: (7−3+1 × 7−3+1) و بالتالي فإن الناتج يساوي 5×5.

الهدف من الشبكات العصبية الالتفافية هو الاستفادة القصوى من كل بكسل في الصورة و لكن عندما يتم تطبيق المرشح على الصورة كما هي فإنه يمر على النقاط التي في منتصف الصورة أكثر من مرة و بالتالي فإن الاستفادة من هذه النقاط تكون أكثر من النقاط التي في الحواف حيث يمر المرشح عليها مرة واحدة فقط، و لحل مشكلة فقدان المعلومات المهمة حول زوايا الصورة يتم استخدام الحشو Padding و هو عبارة عن طبقة من الأصفار يتم إضافتها حول الصورة بالكامل، فعند إضافة بكسل قيمته صفر إلى الصورة فإنه خصائص الصورة لا تتغير و تكون كما هي و بالتالي تتم الاستفادة من كل المعلومات المهمة الموجودة في الزوايا بشكل مثالي دون التغيير في الصورة الأصلية.

عمليا يوجد نوعين من الحشو Valid Padding و Same Padding، الأول يعني لا يوجد حشوة على الإطلاق و بالتالي عند تطبيق المرشح على الصورة التي لا تحتوي على حشو فإن حجم الصورة المخرجة سيكون أقل من الصورة المدخلة، و النوع الثاني هو النوع الأكثر استخداما و يعني إضافة حشو للصورة و بالتالي عند تطبيق المرشح على الصورة التي تحتوي على حشو فإن حجم الصورة المخرجة سيكون مساويا لحجم الصور المدخلة و سيتم الاستفادة من كل السمات المهمة الموجودة في الصورة بما في ذلك الموجودة في الزوايا، يتم إضافة طبقة واحدة من الحشو أو أكثر استنادا إلى حجم المرشح المستخدم فكلما كان حجم المرشح كبير كلما يتم إضافة طبقات إضافية من الحشو إلى الصورة، و لتحديد عدد طبقات الحشو التي يتم إضافتها إلى الصورة استنادا على حجم المرشح المستخدم يتم استخدام القانون التالي: (P=F-1/2)، يمكننا استخدام القانون لحساب حجم الحشو في المثال السابق: P = (3−1/2)، حيث 3 تشير إلى حجم المرشح و بالتالي فإن الناتج يساوي 1.

عن التعامل مع المرشحات هناك مصطلح مهم جدا يجب أخذه في عين الاعتبار و هو مصلح Strides و المقصود به هو عدد الخطوات التي يتحركها المرشح أثناء قيامه بالمسح على الصورة عاموديا و أفقيا، و لحساب حجم الصورة المخرجة عند تطبيق المرشح عليها وبالاعتماد على عدد الخطوات التي سيتحركها المرشح يتم استخدام القانون التالي: ((N+2P−F/S) +1).

حيث S تمثل Strides، و بتطبيق القانون على المثال السابق و إذا افترضنا أن عدد خطوات المرشح هي خطوة واحدة في كل مرة فان حجم صورة الخرج يساوي (1+ (1 / 3− (2×1) +7)=7.

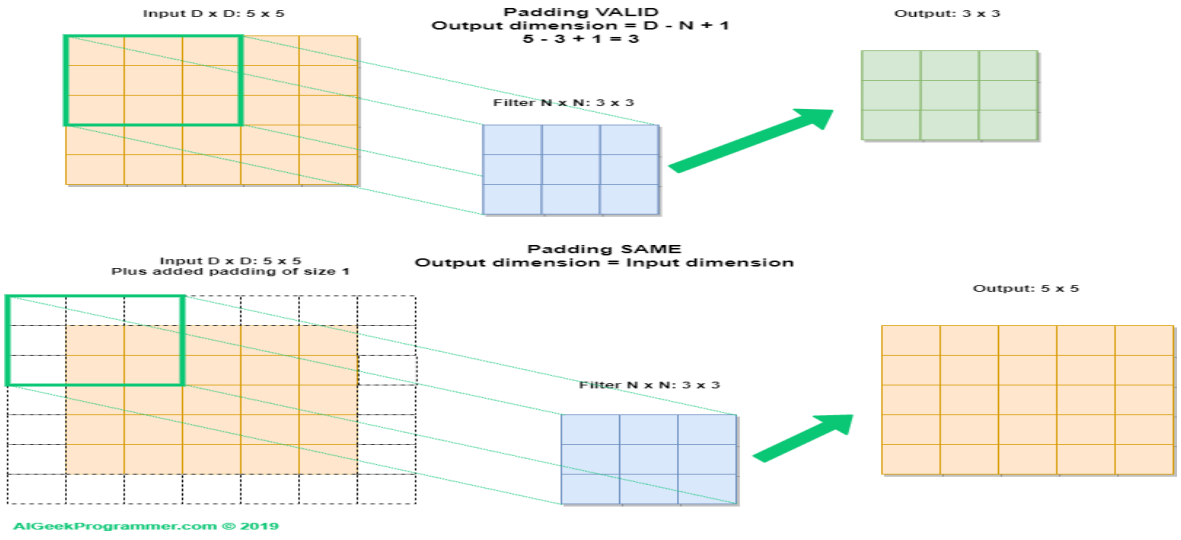

شكل (3.2) يوضح عملية تطبيق Valid Padding و Same Padding

عند التعامل مع الصور الغير ملونة مثل صور التدرج الرمادي Grayscale تكون الصورة عبارة عن مصفوفة ثنائية الأبعاد (الطول× العرض) من قيم تتراوح بين (0−255) حيث 0 يمثل اللون الأسود و 255 تمثل اللون الأبيض و ما بينها يعبر عن تدرج اللون الرمادي فكلما اقتربت القيمة من 0 كان اللون أفتح وكلما اقتربت من 255 كان اللون أغمق، يتم حفظ الصور في الكمبيوتر على شكل مصفوفة من الأرقام تعرف هذه المصفوفة أيضا باسم القناة، أما الصور الملونة فهي عبارة عن مصفوفة ثلاثية الأبعاد (الطول × العرض × العمق) يشير العمق إلى عدد القنوات اللونية و هي ثلاث قنوات متمثلة في اللون (الأحمر و الأخضر و الأزرق)، و بما أن كل قناة هي عبارة عن مصفوفة فإن قيم البكسل و التي تتراوح بين(0−255) تعبر عن تدرج لون كل مصفوفة من المصفوفات الثلاث، كل لون من الألوان الاخرى يتكون عن طريق تفاوت قيم البكسل في هذه المصفوفات و يتم

تمثيله كالتالي: (R(0−255),G(0−255), B(0−255)) حيث R تمثل نسبة اللون الأحمر Red و G تمثل نسبة اللون الأخضر Green و B تمثل نسبة اللون الأزرق Blue.

هذا ما يفسر أن التعامل مع الصور الملونة في الشبكات العصبية يختلف عن التعامل مع صور التدرج الرمادي حيث أن عمق المرشحات التي يتم تطبيقها يجب أن يكون مساويا لعمق الصورة المدخلة، فبالتالي يكون عمق المرشح ثلاث قنوات لونية مع الصورة الملونة ويكون عمقه واحد عند التعامل مع صور التدرج الرمادي [7،10].

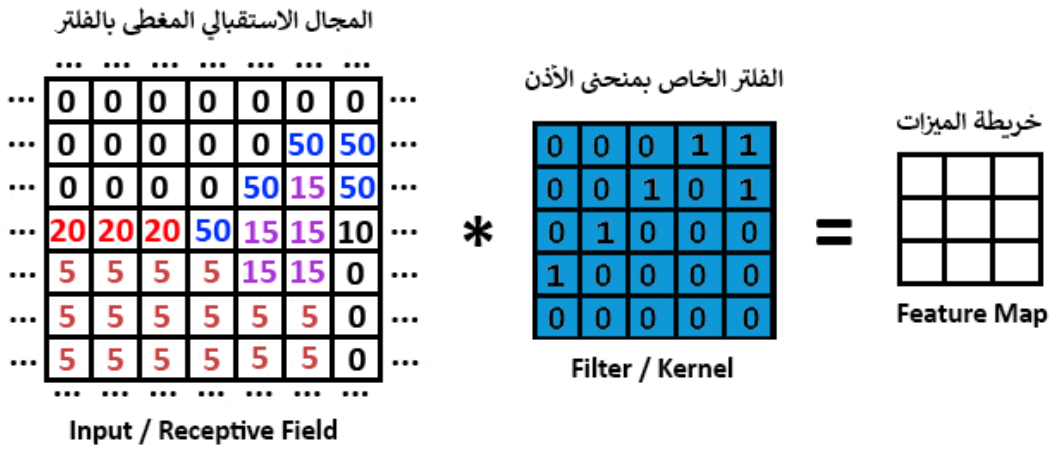

شكل (4.2) يوضح عملية تطبيق المرشح على صور التدرج الرمادي [7]

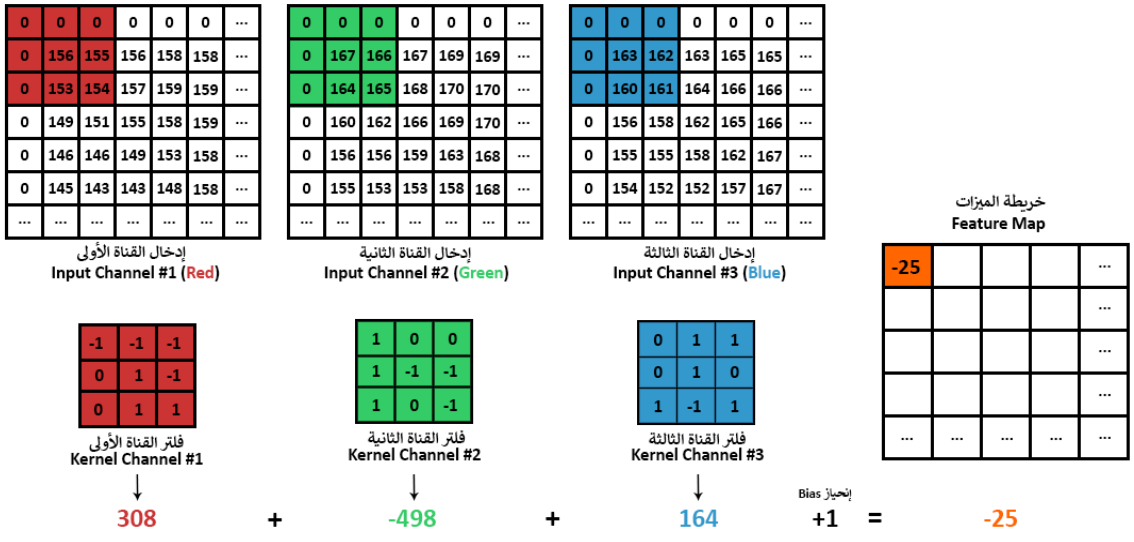

شكل (5.2) يوضح عملية تطبيق المرشح على الصور الملونة [7]

2.5.2 طبقة وحدة التصحيح الخطية RELU Layer

دوال التفعيل أو دوال التنشيط Activation Function هي عبارة عن مجموعة من الدوال الغير خطية و التي تستخدم في تقييد المدخلات في نطاق معين من خلال تفعيل أو عدم تفعيل المدخل حسب المدى المحدد في كل دالة، تتميز دوال التفعيل الغير خطية بقدرتها على التعامل مع البيانات المعقدة و التي من الصعب تمثيلها بشكل خطي مما يسمح للشبكة التعلم و كذلك إنجاز المهام الأكثر تعقيدا.

تعتبر وحدة التصحيح الخطية RELU أحد دوال التفعيل الأكثر استخداما إذ تتميز بتقليل كمية الحسابات المنجزة من خلال عدم تفعيل جميع النقاط في خرائط السمات، يتم تمثيل دالة RELU كالتالي: $f(x)=Max(0,x)$ وبالتالي فإن نطاق القيم التي يتم الحصول عليها عند تطبيقها يكون محصور ما بين $(0،+\infty)$ تقوم دالة RELU بتحويل جميع القيم السالبة إلى صفر مع إبقاء القيم الموجبة كما هي، وبالتالي فإن عملها يتلخص في تفعيل جميع النقاط التي تمثل الميزات المهمة المتمثلة في القيم الموجبة وإقصاء النقاط التي لا تمثلها والتي تحمل القيم السالبة كما تم توضيح ذلك سابقا.

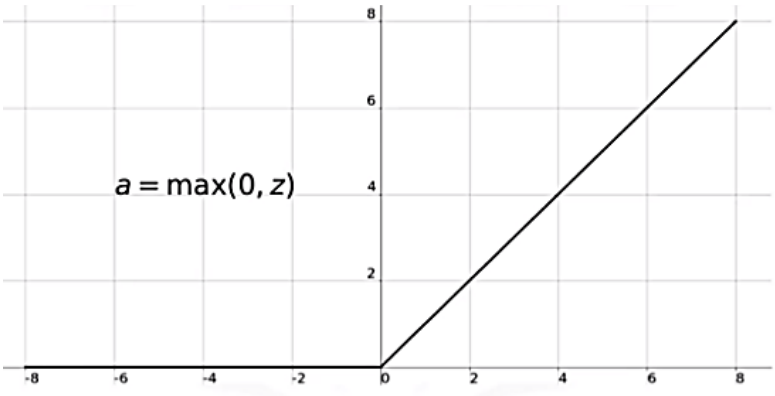

شكل (6.2) يوضح عملية تطبيق دالة RELU [7]

توجد العديد من دوال التفعيل الأخرى الغير خطية مثل الدالة السينية Sigmoid ودالة الظل الزائد Tanhودالة Softplus و غيرها، تستخدم دالة RELU كدالة أساسية يتم تطبيقها على مخرجات الطبقة الالتفافية المتمثلة في خرائط السمات نظرا لأنها تتضمن عددا قليل من العمليات و تقلل من التكلفة الحسابية دون التأثير على السمات المهمة التي يتم استخراجه [1].

3.5.2 طبقة التجميع Pooling Layer

تحتوي الشبكات الالتفافية على مجموعة من طبقات التجميع لتبسيط العمليات الحسابية التي تجرى على الصور تعرف هذه الطبقات أيضا باسم طبقات الاختزال الجزئي، تقوم طبقة التجميع بعملية الاختزال على طول الأبعاد المكانية (العرض و الارتفاع) لخريطة السمات، حيث تقلل من حجم كل خريطة من خرائط السمات و لكنها تحتفظ بالمعلومات الأكثر أهمية، يوجد نوعين من الاختزال Max Pooling و Average Pooling ، عند استخدام النوع الأول فإنه يتم اختيار الميزات ذات القيمة الأعلى أي أنه يعطي أهمية أكبر لتلك الميزات التي لها قيمة أكبر من غيرها، و عند تطبيق النوع الثاني فإنه يقوم بحساب متوسط القيم التي يتم تحديدها و يتم وضع هذه القيم في خريطة السمات الجديدة و التي ستحتوي على سمات مختلفة و أقل من السمات تم استخراجها من الطبقة الالتفافية.

عند تطبيق عملية الاختزال يتم استخدام مرشح و لكن في هذه المرة لا يحتوي على قيم وظيفته تحديد النقاط التي سيتم تطبيق عملية الاختزال عليها، يعمل المرشح بنفس الطريقة التي تعمل بها المرشحات في الطبقة الالتفافية حيث يقوم بالالتفاف على الصورة من الاعلى إلى الاسفل و من اليسار إلى اليمين ليمسح الصورة كاملة، يجب أن يكون حجم المرشح صغير بحيث لا يتجاوز حجمه 2×2 أو 3×3 كحد أقصى و ذلك لتجنب فقدان المعلومات المهمة في الصورة بشكل كبير فكلما كان المرشح أكبر كلما كان حجم خرائط السمات أقل وبالتالي فإن عدد السمات المستخرجة سيكون قليل. [1،10]

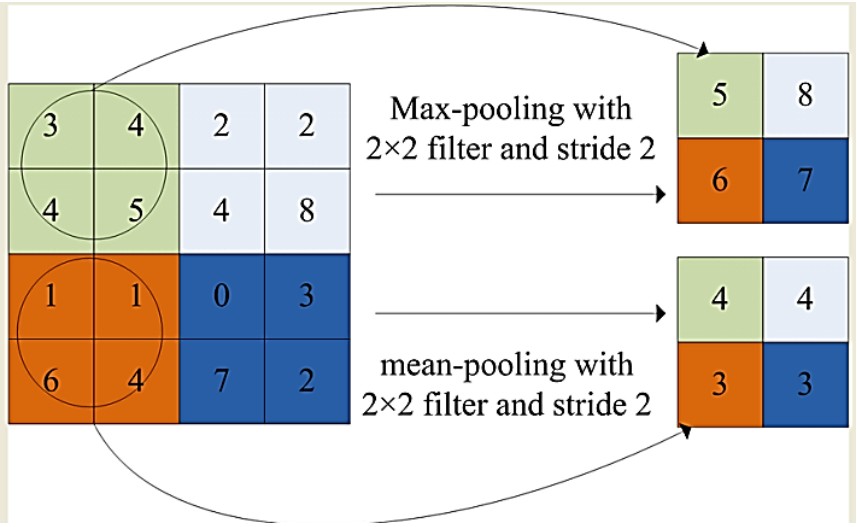

شكل (7.2) يوضح ناتج تطبيق Max Pooling و Average Pooling [7]

4.5.2 طبقة التسطيح Flatten Layer

تستخدم طبقة التسطيح لتحويل المدخلات ذات الأبعاد المتعددة إلى بعد واحد، حيث تستخدم في الانتقال من الطبقات الالتفافية إلى الطبقة المتصلة بالكامل، يتم تطبيق عملية التسطيح على مخرجات الطبقات الالتفافية وذلك لأن الطبقات المتصلة بالكامل تستقبل فقط مدخلات ببعد واحد، لا تؤثر عملية التسطيح على خصائص الصورة، الشكل التالي يوضح عملية تطبيق التسطيح على الصور الملونة.

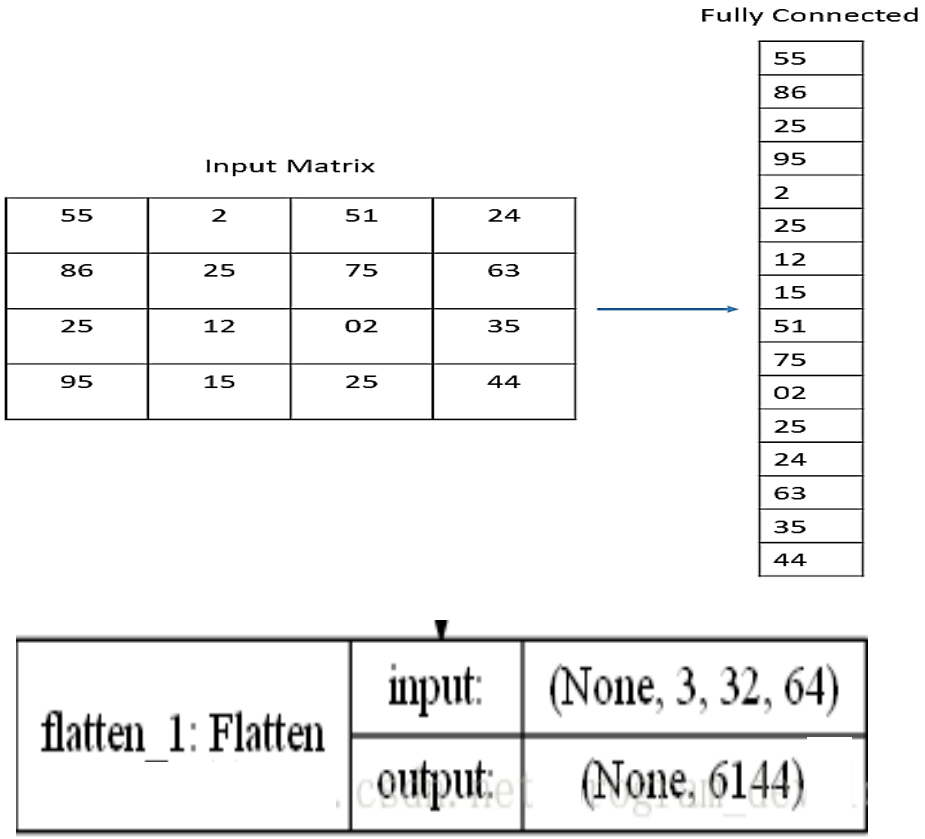

شكل (8.2) يوضح تطبيق عملية Flatting [7]

يوضح الشكل السابق عملية تحويل صورة تحتوي على ثلاث أبعاد إلى صورة ببعدين عن طريق ضرب طول الصورة في عرضها في العمق.

5.5.2 طبقة الاتصال الكامل Fully Connected Layer

الطبقة كاملة الاتصال هي عبارة عن شبكة عصبية اصطناعية تقليدية متعددة الطبقات يشير مصطلح كاملة الاتصال إلى أن كل خلية عصبية في الطبقة السابقة متصلة بكل خلية عصبية في الطبقة

التالية كما تم توضيح ذلك سابقا، في حين تم استخدام طبقتي الالتفاف Convolution و التجميع Pooling في استخراج الخصائص عالية المستوى للصورة المدخلة، تستخدم الطبقة كاملة الاتصال هذه الخصائص في عملية التدريب و ذلك لتصنيف الصورة المدخلة إلى عدة فئات بناء على الهدف الذي يتم تحديده.

6.5.2 طبقة التسرب Dropout Layer

يقصد بالتسرب تجاهل أو تعطيل بعض الخلايا (العصبونات) بشكل عشوائي في طبقات الشبكات العصبية أثناء عملية التدريب، و بالتالي سيقوم بمنع النموذج من التركيز على خاصية معينة و يتم إجباره على التعلم من كل الخصائص الموجودة و لا يأخذ خاصية واحدة كقاعدة في التعلم و يعتمد عليها بشكل دائم، حيث يستخدم مجموعة جزئية من العصبونات في كل تكرار Epoch، تكمن الاستفادة من تطبيق عملية Dropout هو أن الشبكة تصبح أقل حساسية للأوزان المحددة للخلايا العصبية، و ينتج عن استخدامها شبكة قادرة على التعميم Generalization بشكل أفضل ولا تعاني من فرط التخصيص Overfitting على بيانات التدريب، يتم تحديد معدل الحذف بواسطة المستخدم حيث يأخذ قيمة بين 0 و1، فعند تعيين قيمة التسرب على 0.5 سيتم تعطيل 50% من العصبونات بشكل عشوائي في كل تكرار، يجب اختيار قيمة الحذف العشوائي بدقة فاختيار قيم أكبر من 0.5 قد يؤدي إلى مشكلة أخرى و هي Underfitting، واختيار قيم صغيرة قد لا يحل المشكلة إذا كان النموذج يعاني من فرط التخصيص، يتم استخدام التسرب فقط أثناء تدريب النموذج و لا يتم استخدامه عند التقييم النهائي للنموذج أو عند استخدامه [11].

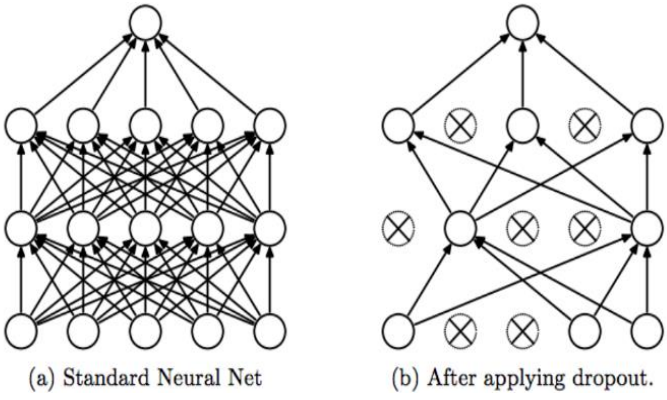

شكل (9.2) يوضح تطبيق عملية Dropout [7]

7.5.2 طبقة التنعيم Softmax layer

يتم في طبقة التنعيم استخدام وظيفة التنشيط Softmax و التي تأخذ متجهات من الأرقام الحقيقية و التي تمثل نتائج مخرجات النموذج كمدخلات و تضعها في توزيع احتمالي حيث تعمل على تقييدها في نطاق ما بين 0 و 1، من المهم ملاحظة أن طبقة Softmax تقوم فقط بتغيير نطاق القيم لكل عينة من مجموعة البيانات وبالتالي فإنها لا تقوم بإجراء أي تغيير على عدد العصبونات التي تم تمريرها إليها، يتم حساب دالة Softmax بواسطة المعادلة التالية:

$$Softmax(z)_i = \frac{e^{z_i}}{\sum_{j=1}^{N} e^{z_j}}$$

تشير z_i إلى العقدة التي سيطبق عليها التنعيم و N تشير إلى العدد الإجمالي لعقد المخرجات والتي تساوي في حالة التصنيف الثنائي عقدتين، وتمثل z_j كل عقد المخرجات بما فيها العقدة التي يتم حساب احتمالها [1].

6.2 الدراسات السابقة

مع وجود العديد من مجموعات البيانات المنتشرة و المتنوعة و كذلك وجود عدة نماذج تستخدم للتصنيف هناك العديد من الدراسات السابقة التي قامت بتصنيف سرطان الثدي سواء كان باستخدام تقنيات التعلم العميق أو غيرها، سيتم تقسيم الدراسات السابقة إلى دراسات استخدمت نفس مجموعة البيانات المستخدمة في هذا البحث BreakHis، و دراسات استخدمت النموذج المستخدم Alexnet في التنصيف، سيتم التركيز على عرض النموذج المستخدم و مجموعة البيانات و التقنيات و الأدوات المستخدمة و الدقة التي توصلت إليها كل دراسة.

أشارت الدراسة [5]، إلى أهمية استخراج الميزات من الصورة و التي تعتبر خطوة أساسية في عملية التصنيف، و أجريت مقارنة بين طريقتين الأولى تتمثل في استخراجك الميزات باستخدام الطرق اليدوية التقليدية، و الثانية هي استخدام مفهوم نقل التعلم وذلك من خلال نموذج مدرب مسبقا للتصنيف متعدد الفئات باستخدام مجموعة بيانات BreakHis، تم تدريب النماذج باستخدام الميزات المستخرجة يدويا عن طريق استخدام تقنية استخراج الميزات القوية المتسربة (SURF) و تقنية تحويل الميزات الثابتة للمقياس الكثيف (DSIFT)، و تم ترميز هذه الميزات المستخرجة بواسطة طريقة الترميز

الخطي المقيد محليا (LLC)، في النموذج الذي تم تدريبه مسبقا تم استخدام كل من VGG−16 و VGG−19 و ResNet50 وGoogLeNet لاستخراج الميزات، وكانت النتائج توضح أنه عند استخدام طريقة استخراج الميزات يدويا أعطى استخدام SURF + CNN أفضل نتائج حيث تحصل على نسبة دقة تساوي 92.8%، وبالنسبة للنماذج التي تم تدريبها مسبقا حقق استخدام كل من GoogLeNet + CNN أعلى نسبة دقة تساوي 94% وكلاهما لعامل تكبير400x.

قدمت الدراسة [12]، نموذجا باستخدام SE−ResNet مصغر و طبقة كاملة الاتصال، و اقترحت تجربة جدولة جديدة لمعدل التعلم و ذلك للحصول على أداء أفضل دون تعديل معدل التعلم بشكل معقد، تم استخدام مجموعة بيانات BreakHis لمقارنة أداء النموذج في التصنيف الثنائي و التصنيف المتعدد، بعد تدريب النموذج أظهرت النتائج النهائية أن النموذج حقق دقة تتراوح بين 98.87% و 99.34% للتصنيف الثنائي و دقة تتراوح بين 90.66% و 93.81% للتصنيف متعدد الفئات.

ووفقا للدراسة التي أجريت بواسطة الدراسة [13]، و التي أشارت إلى أن ضبط المعلمات و تهيئة الأوزان تعتبر مهمة رئيسية لتكييف نماذج الشبكات العصبية الالتفافية المدربة مسبقا، تم استخدام أسلوب نقل التعلم باستخدام نموذجي Alexnet و VGG−16، وتم أيضا تطوير نموذج DCNN و مقارنة أدائه بالنماذج المدربة مسبقا على مجموعة بيانات BreakHis ، بعد تدريب النموذج حقق نموذج DCNN دقة أعلى من النماذج الأخرى المستخدمة في هذه الدارسة، حيث حقق نسبة دقة تساوي 93.38% في التصنيف الثنائي و متوسط دقة 89.29% في التصنيف المتعدد.

وقارنت الدراسة [14]، بين نهجين للتعلم الآلي في التصنيف التلقائي لصور أنسجة سرطان الثدي لمجموعة بيانات BreakHis، يعتمد النهج الأول على استخراج مجموعة من الميزات يدويا و تشفيرها بواسطة حقيبة الكلمات BOW و استخدام التشفير الخطي المقيد محليا (تشفير LLC) والتدريب بواسطة آلات المتجه الداعم SVM، و يعتمد النهج الثاني على استخدام الشبكات العصبية الالتفافية CNN في التصنيف، وتم اختبار أيضا تقنيات زيادة مجموعة البيانات بشكل تجريبي لتعزيز دقة الشبكة العصبية الالتفافية، أظهرت النتائج تفوق الشبكات العصبية الالتفافية بعد تدريبها على التصنيف القائم على استخراج الميزات يدويا، حيث حققت دقة بين 96.15% و 98.33% في التصنيف الثنائي و 83.31% و 88.23% في التصنيف متعدد الفئات.

وفي الدراسة [8]، تم اقتراح بنية شبكة عصبية التفافية لإنشاء نظام آلي للتصنيف المتعدد لصور الأنسجة لسرطان الثدي يوفر هذا النظام الآلي إنتاجية عالية في تشخيص الفئات الثمانية المختلفة لسرطان الثدي من خلال مجموعة بيانات BreakHis المتوازنة، يستخدم النظام منهجية تدريب لتعلم السمات المميزة من الصور ذات مستويات التكبير المختلفة و تم أيضا استخدام تقنيات زيادة البيانات للتغلب على مشكلة فرط التجهيز، تم تحسين أداء بنية CNN من خلال اعتماد استراتيجية تجميع polling مناسبة وتقنية التحسين optimization، حقق النموذج دقة تساوي (80.76%, 76.5%, 74.21%, 79.90%) عند معاملات التكبير (40x , 100x , 200x , 400x) على التوالي.

ونظرا لصعوبة عملية فحص خلايا الأنسجة لسرطان الثدي و التي تتطلب الكثير من الوقت استخدمت الدراسة [15]، الشبكات العصبية العميقة التي تعمل بمفهوم مفهوم التصنيف الخاضع للإشراف، و ذلك باستخدام مجموعة البيانات (Bioimaging Challenge 2015 Breast Histology) و التي تحتوي على 240 صورة للتدريب و 20 صورة للاختبار، وذلك لتصنيف صور الأنسجة بين أربع فئات من الأورام، تم تطبيق مفهوم نقل التعلم باستخدام AlexNet و GoogleNet و ResNet ، حقق نموذج AlexNet نسبة دقة تساوي 82.3% في حين حقق نموذج GoogleNet دقة تساوي 83.6% و تحصل نموذج ResNet على نسبة دقة تساوي 85%.

استخدمت معظم أنظمة التشخيص بمساعدة الكمبيوتر CAD طرقا تقليدية لاستخراج الميزات يدويا و التي تعتبر غير دقيقة في التشخيص و تستغرق وقتا طويلا هذا ما أشارت له الدراسة [16]، حيث اقترحت استخدام الشبكات العصبية الالتفافية و بالتحديد نموذج AlexNet مدرب مسبقا لاستخراج الميزات بشكل أعمق و أكثر دقة من مجموعة بيانات BreaKHis، وذلك لتشخيص سرطان الثدي على أنه حميد أو خبيث، أجرت الدراسة أربع تجارب وفقًا لعامل التكبير (40x و 100x و 200x و 400x)، تحصل النظام المقترح على دقة تساوي (95%، 97% ، 90% ، 99.37%) لمجموعات البيانات على التوالي.

اعتمدت الدراسة [17]، على الشبكات عصبية الالتفافية العميقة DCNN في الكشف عن صور الأنسجة لسرطان الثدي و ذلك باستخدام مجموعة بيانات BreaKHis، حيث استخدمت نموذج VGG-M مدرب مسبقا وذلك لأداء مهمة التصنيف الثنائي، تحصل النموذج على متوسط نسبة دقة تساوي 86.80%.

تطرقت الدراسة [18]، إلى استخدام مزيج من تقنيات نقل التعلم و المعالجة المسبقة الدقيقة و استخدام الزيادة الافتراضية للبيانات و ذلك من أجل التعامل مع محدودية البيانات المستخدمة المتمثلة في مجموعة البيانات Digital Database For Screening Mammography (DDSM)، استخدمت الدراسة ثلاث نماذج و هي Baseline و AlexNet و GoogLeNet، أعطى نموذج GoogLeNet نسبة دقة تساوي 92% يليه نموذج AlexNet بنسبة دقة تساوي 89% وأخيرا حقق نموذج Baseline نسبة دقة تساوي 60%.

وفي الدراسة التي أجريت بواسطة [19]، تم استخدام الشبكات العصبية العميقة DCNN و المدربة مسبقا في تشخيص صور الأشعة لسرطان الثدي و المأخوذة من المستودع الطبي الرقمي لسرطان الثدي (BCDR)، تمت مقارنة نتائج كل من GoogLeNet و AlexNet و شبكات CNN الضحلة (CNN2,CNN3)، تشير النتائج التجريبية إلى أن GoogLeNet حقق أفضل أداء بنسبة دقة تساوي 81% يليه AlexNet بنسبة دقة تساوي 79% وأخيرا CNN3 والذي أعطى نسبة دقة تساوي 73%.

تعتبر الشبكة العصبية الالتفافية العميقة (DCNN) من خوارزمية التعلم العميق الشائعة و القوية في تصنيف الصور هذا ما أشارت إليه الدراسة [20]، و التي قدمت نموذجين الأول هو نموذج DCNN ببنية معمارية يشار إليها بالضحلة و الثاني هو نموذج DCNN مدرب مسبقا بواسطة AlexNet، للكشف عن سرطان الثدي باستخدام 8000 صورة أشعة للثدي مستخرجة من قاعدة البيانات الرقمية لفحص التصوير الشعاعي للثدي (DDSM)، حقق نموذج DCNN المدرب مسبقا أفضل النتائج بنسبة دقة 89.23%.

اقترحت الدراسة [21]، نظام جديد للتشخيص بمساعدة الكمبيوتر (CAD) لتصنيف صور الأشعة للثدي إلى أورام حميدة أو خبيثة، تم استخدام نهجين لتجزئة الصور يتضمن النهج الأول تحديد منطقة الاهتمام (ROI) يدويا، و الثاني هو استخدام الشبكة العصبية الالتفافية العميقة (DCNN) لاستخراج الميزات، تم استخدام بنية DCNN بواسطة نموذج AlexNet مدرب مسبقا وتم توصيل آخر طبقة متصلة بالكامل بمصنف آلة متجه الدعم (SVM) للحصول على دقة أفضل، طبقت النماذج المقترحة على اثنين من مجموعات البيانات، مجموعة البيانات الأولى هي مجموعة البيانات الرقمية لفحص التصوير الشعاعي للثدي (DDSM) و الثانية مجموعة فرعية من المجموعة الأولى و هي

(CBIS_DDSM)، و لأن مجموعة البيانات المستخدمة عددها قليل تم استخدام الزيادة الافتراضية للبيانات و ذلك لزيادة حجم بيانات الإدخال، حيث يوجد العديد من أشكال زيادة البيانات المستخدمة تم تطبيق عملية الدوران على الصورة في هذه الدراسة، حقق استخدام DCNN مع SVM على مجموعة بيانات CBIS-DDSM أعلى دقة بنسبة تساوي 87.2%.

7.2 الدراسة المقترحة

من خلال مراجعة العديد من الدراسات السابقة التي قامت بتصنيف سرطان الثدي منها [13،15، 16] و التي استخدمت نموذج Alexnet، يتضح مدى اختلاف نسبة الدقة لنفس النموذج سواء تم تدريبه على نفس مجموعة البيانات كما في [13-16]، أو باستخدام مجموعة بيانات مختلفة [15]، و هذا ما يشير إلى مدى تأثر النموذج بالعديد من المتغيرات مثل نوع و عدد الصور المستخدمة و مجموعة البيانات و كذلك عدد مرات تدريب النموذج و نوع التصيف المستخدم سواء كان تصيف ثنائي أو متعدد و غيرها من المتغيرات، وهذا ما تطرقت له أغلبية الدراسات التي قامت بدراسة بعض من هذه المتغيرات و عرضت أفضل النتائج المتحصل عليها، يتشابه البحث المقترح مع الدراسة [16] في استخدامه نفس مجموعة البيانات وكذلك النموذج و لكن يكمن الاختلاف في أنه سيتم تدريب النموذج في هذا البحث لأول مرة على مجموعة البيانات المستخدمة على عكس ما قامت به الدراسة والتي استخدمت نموذج Alexnet مدرب مسبقا.

يهدف البحث إلى تصنيف صور الأنسجة Histology Image لسرطان الثدي باستخدام نموذج Alexnet و الذي سيتم تدريبه على التصيف الثنائي بواسطة مجموعة بيانات Breakhis، و من خلال النتائج التي المتحصل عليها سيتم دراسة و تحديد المتغيرات والعوامل التي تؤثر على النموذج و تحسين أداءه بناء عليها.

8.2 مقارنة بين الدراسات السابقة

بعد مراجعة الدراسات ذات الصلة بموضوع البحث وعرض الدراسة المقترحة و مناقشتها، تم تلخيصها في جدول التالي للمقارنة بينها من حيث مجموعة البيانات المستخدمة ونوع الصور و النموذج المستخدم و كذلك نوع التصنيف و أخيرا تم بعرض أعلى نسبة دقة تم الحصول عليها في كل دراسة.

الجدول (2.1) يوضح المقارنة بين الدراسات السابقة والدراسة المقترحة

أسم الدراسة	السنة	مجموعة البيانات	نوع الصور	النموذج	نوع التصنيف	الدقة
Classification of Breast Cancer using Histology images: Handcrafted and Pre-Trained Features Based Approach	2020	BreakHis	Histology	CNN VGG-16 VGG-19 ResNet50 GoogLeNet	Multi class	CNN = %92.88
Breast cancer histopathological image classification using convolutional neural networks with small SE-ResNet module	2019	BreakHis	Histology	SE-ResNet	Multi class & Bainary	Bainary= %99.34
Deep Convolutional Neural Network for Computer-Aided Detection of Breast Cancer Using Histopathology Images	2021	BreakHis	Histology	Alexnet VGG-16 DCNN	Multi class & Bainary	DCNN_Bainary = %93.38
Classification of Breast Cancer Based on Histology Images Using Convolutional Neural Networks	2018	BreakHis	Histology	SVM CNN	Multi class & Bainary	CNN_Bainary = %98.33
Optimised CNN in conjunction with efficient pooling strategy for the multi-classification of breast cancer	2021	BreakHis	Histology	CNN	Multi class	40 = ×%80.76
Classification of Breast Cancer Histology Images Using Transfer Learning	2019	Bioimaging Challenge 2015 Breast Histolog	Histology	AlexNet GoogleNet ResNet	Multi class	GoogleNet = %83.6
Classification of Histopathological Images for Early Detection of Breast Cancer Using Deep Learning	2021	BreaKHis	Histology	AlexNet	Binary	400 = ×%99.37
Breast Cancer Classification in Histopathological Images using Convolutional Neural Network	2018	BreaKHis	Histology	VGG-M	Binary	%86.80
Breast Mass Classification from Mammograms using Deep Convolutional Neural Networks	2016	DDSM	Mammography	Baseline AlexNet GoogLeNet	Binary	GoogLeNet = %92

أسم الدراسة	السنة	مجموعة البيانات	نوع الصور	النموذج	نوع التصنيف	الدقة
Transferring deep neural networks for the differentiation of mammographic breast lesions	2019	BCDR	Mammography	GoogLeNet AlexNet CNN2 CNN3	Binary	GoogLeNet = %81
Breast Cancer Detection using Deep Convolutional Neural Network	2019	DDSM	Mammography	DCNN Alexnet	Binary	AlexNet = %89.23
Breast cancer detection using deep convolutional neural networks and support vector machines	2019	CBIS_DDSM DDSM	Mammography	AlexNet ROI	Binary	CBIS_DDSM & AlexNet= %87.2

الفصل الثالث

منهجية البحث

3. المقدمة

يحتوي هذا الفصل على شرح مفصل للمنهجية المستخدمة في هذا البحث حيث سيتم توضيح الأدوات والتقنيات المستخدمة في كل خطوة من خطوات المنهجية، و يحتوي أيضا على تعريف لمنصات العمل التي تم استخدامها و أخيرا المكتبات و الأدوات التي تمت الاستعانة بها.

1.3 منهجية البحث

تعد منهجية البحث أحد أهم أجزاء البحث العلمي، و هي عبارة عن مجموعة من الخطوات التي يقوم بها الباحث في دراسته، بمعنى آخر هي الخطوات التي يجب أن يسير عليها الباحث أثناء قيامه بالبحث العلمي و التي من خلالها سيجد الحل المناسب للمشكلة، يوضح الشكل التالي خطوات المنهجية المتبعة في هذا البحث.

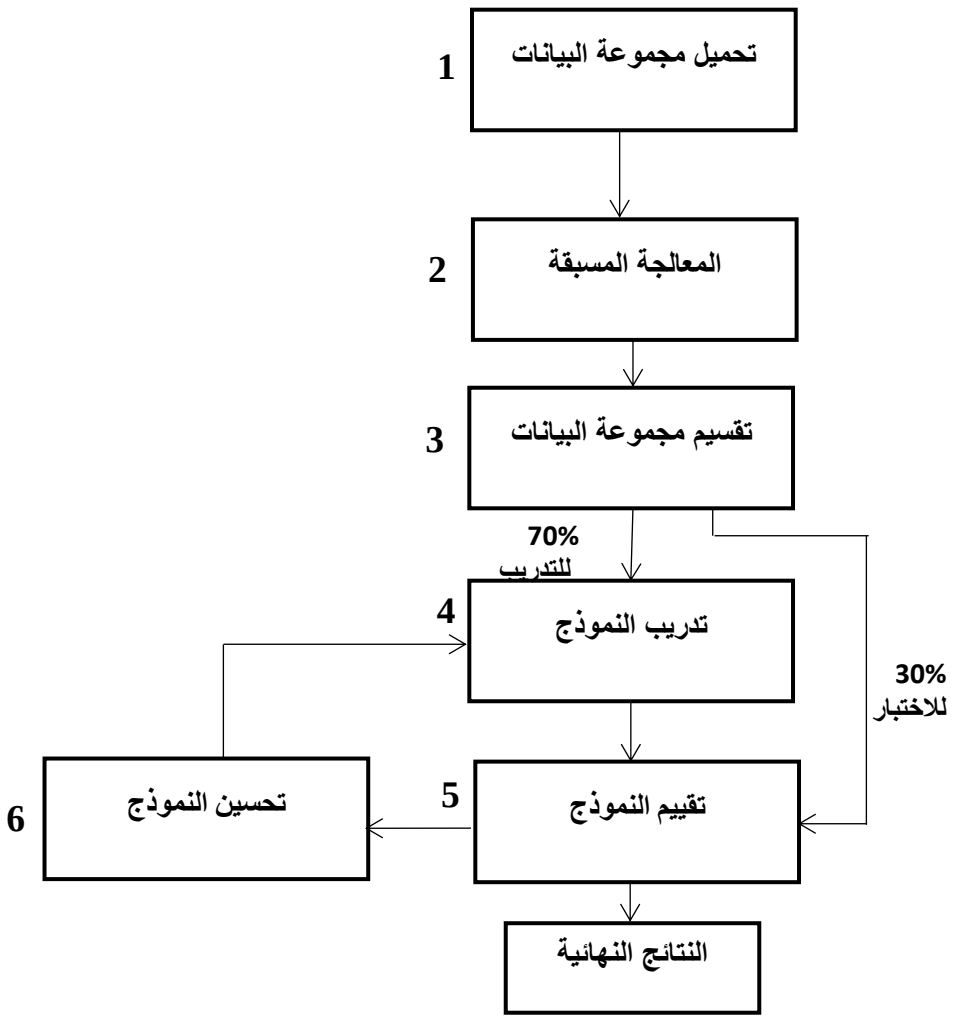

الشكل (1.3) يوضح منهجية البحث

1.1.3 تحميل مجموعة البيانات

تعتبر خطوة التحميل هي الخطوة الأولى من خطوات المنهجية المتبعة، تم في هذا البحث تحميل مجموعة بيانات Breakhis، تعتبر مجموعة البيانات جاهزة للاستخدام المباشر في التحليل التجريبي و مشاريع التعلم الآلي و التعلم العميق [9]، تحتوي مجموعة البيانات على إجمالي 7909 صورة نسيجية لسرطان الثدي 2480 عينة حميدة و 5429 عينة خبيثة، تم جمع و أخذ العينات من 82 مريض و تم التقاطها بواسطة المجهر باستخدام 4 عوامل تكبير مختلفة و هي: (×40 ، ×100 ، ×200 ، ×400)، و تحتوي على فئتين من صور الأورام الحميدة و صور الأورام الخبيثة ، تحتوي فئة الأورام الحميدة على 4 أنواع من الورم الحميد و هي: الورم الأنبوبي Tubular Adenoma (TA)، الورم الورقي Phyllodes Tumor (PT)، ورم الغدد الليفية Fibroadenoma (F)، و ورم الغدد Adenosis Tumor (A)، و تحتوي فئة الأورام الخبيثة على 4 أنواع من الورم الحميد و هي: السرطان الحليمي Papillary Carcinoma (PC)، السرطان المخاطي Mucinous Carcinoma (MC)، السرطان الفصيصي Lobular Carcinoma (LC)، و سرطان الأقنية Ductal Carcinoma (DC)، حجم كل صور في مجموعة البيانات (3×640×700) بكسل تم حفظها بتنسيق PNG.

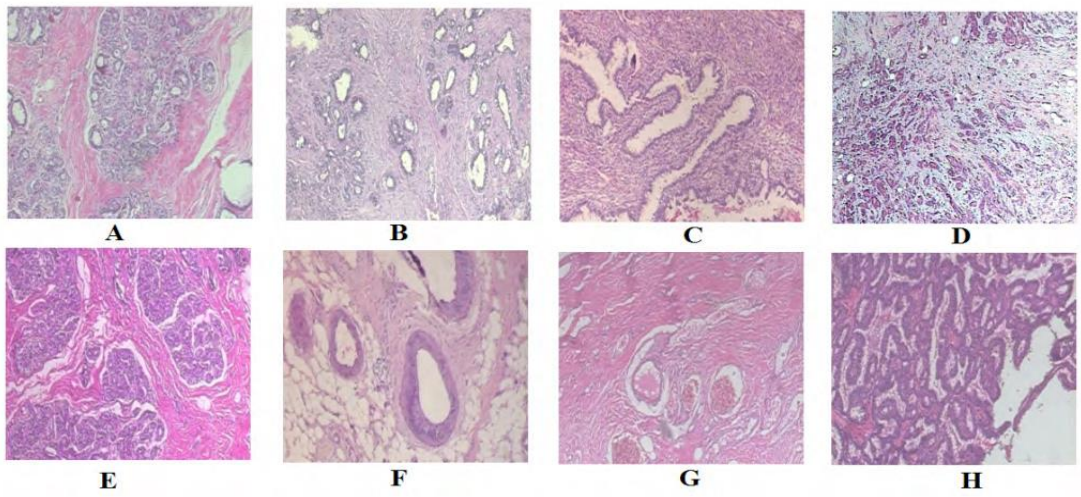

شكل (2.3) يوضح الصور الخاصة بكل نوع من الامراض [14]

(A) : Adenosis, (B) : Fibroadenoma, (C) : Phyllodes Tumor, (D) : Tubular Adenoma (E) : Ductal Carcinoma, (F) : Lobular Carcinoma, (G) : Mucinous Carcinoma, (H) : Papillary Carcinoma.

الجدول التالي يوضح عدد الصور في كل فئة من الفئات المذكورة لمجموعة البيانات المستخدمة:

جدول (1.3) يوضح مجموعة بيانات Breakhis [14]

Classes	Subtypes	Magnification Factor				Total
		40×	100×	200×	400×	
Benign(B)	Adenosis(A)	114	113	111	106	444
	Fibroadenoma(F)	253	260	264	237	1,014
	Tubular Adenoma(TA)	109	121	108	115	453
	Phyllodes Tumor(PT)	149	150	140	130	569
Malignant(M)	Ductal Carcinoma(DC)	864	903	896	788	3,451
	Lobular Carcinoma(LC)	156	170	163	137	626
	Mucinous Carcinoma(MC)	205	222	196	169	792
	Papillary Carcinoma(PC)	145	142	135	138	560
Total		1,995	2,081	2,013	1,820	7,909

2.1.3 المعالجة المسبقة Preprocessing

تتمثل خطوة المعالجة المسبقة في إجراء مجموعة من العمليات على الصور التي تم تحميلها قبل إدخالها للنموذج، تعتبر مجموعة البيانات التي تم تحميلها جاهزة للاستخدام المباشر دون الحاجة إلى إجراء أي عمليات معالجة مسبقة عليها [9]، في هذا البحث سيتم إجراء بعض العمليات التي تتطلبها عملية التدريب دون التعديل على محتوى الصورة، في هذا البحث تم بناء نموذج له القدرة على التصنيف الثنائي بحيث يقوم بالتعرف على الصورة المدخلة و تصنيفها و تحديد ما إذا كانت الصورة تنتمي إلى فئة الأورام الحميدة أو الخبيثة، و بما أن مجموعة البيانات المستخدمة تحتوي على أربعة أنواع فرعية لكل فئة من الأورام، تمت إعادة تجميع مجموعة البيانات بحيث تم دمج الأنواع الأربع لكل فئة معا، الجدول التالي يوضح مجموعة البيانات بعد إعادة ترتيبها.

جدول (2.3) يوضح مجموعة البيانات بعد الترتيب

Magnification Factor	Benign (B)	Malignant (M)	Total
40×	625	1,370	1,995
100×	644	1,437	2,081
200×	623	1,390	2,013
400×	588	1,232	1,820
Total	2,480	5,429	7,909

ومن ثم تم تغيير حجم الصور في مجموعة البيانات من 640×700 إلى 224×224 لكي تتناسب مع الحجم الذي يتطلبه نموذج Alexnet المستخدم.

3.1.3 تقسيم مجموعة البيانات

في هذه المرحلة سيتم تقسيم مجموعة البيانات إلى مجموعتين مجموعة للتدريب ومجموعة للاختبار، تم أولا تقسيم مجموعة البيانات إلى 70% لمجموعة التدريب و 30% لمجموعة الاختبار، و من ثم تم تغييرها في مرحلة من مراحل التدريب إلى 80% لمجموعة التدريب و 20% لمجموعة الاختبار، تستخدم مجموعة التدريب في مرحلة تدريب النموذج حيث يتم تمرير الصور و الفئة التي تنتمي إليها كل صورة للنموذج، أما في مرحلة الاختبار تستخدم مجموعة الاختبار و يتم تمرير الصورة فقط دون تحديد الفئة التي تنتمي إليها لكي يتعرف عليها النموذج، و من ثم يتم تقييم النموذج عن طريق حساب مجموع الخطأ الذي ينتجه النموذج بعد كل مرحلة تدريب و أيضا حساب دقته من خلال عدد الصور التي قام بتصنيفها بطريقة صحيحة و عدد الصور التي قام بتصنيفها بطريقة خاطئة.

4.1.3 تدريب النموذج

النموذج المستخدم و الذي تم تدريبه في هذا البحث هو نموذج AlexNet [11]، يعتبر النموذج أحد نماذج الشبكات العصبية الالتفافية (CNN)، في حين توجد العديد من نماذج الشبكات العصبية الالتفافية و التي تختلف في عدد الطبقات و ترتيبها و تتشابه في إنها جميعا تتكون من الطبقات

الأساسية للشبكات العصبية الالتفافية، يتكون نموذج AlexNet من ثمان طبقات، خمسة طبقات التفافية و ثلاثة طبقات متصلة بالكامل، يقصد بالطبقات الالتفافية هنا أن كل طبقة تتكون من (الطبقة الالتفافية + طبقة التجميع + طبقة RELU) هذا بالنسبة للطبقات الأولى و الثانية و الخامسة، أما بالنسبة للطبقتين الثالثة و الرابعة فهي لا تحتوي على طبقة التجميع، و يعتبر نموذج AlexNet أول نموذج يستخدم طبقة وحدة التصحيح الخطية RELU كوظيفة تنشيط في الشبكات العصبية، رغم بساطة النموذج مقارنة بالنماذج الأخرى للشبكات العصبية الالتفافية و التي تعتبر ذات بنية معقدة و متشابكة إلا أنه يعطي نتائج ذات دقة عالية [16]، الشكل التالي يوضح بنية نموذج Alexnet.

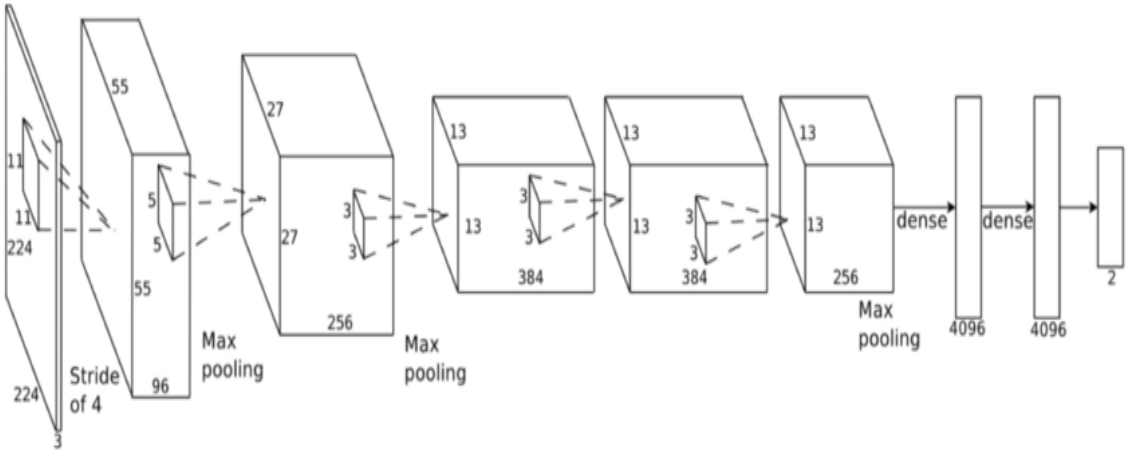

الشكل (3.3) يوضح بنية نموذج Alexnet

الجدول التالي يشرح بالتفصيل معاملات كل طبقة من طبقات نموذج Alexnet و القيم الخاصة بكل معامل.

جدول (3.3) يوضح قيم معاملات نموذج Alexnet

Layer	Filters/Neurons	Filter Size	Stride	Padding	Size Of Feature Map	Activation Function
Input	-	-	-	-	224×224×3	-
Conv 1	96	11×11	4	-	56×56×96	RELU
Max Pool 1	-	3×3	2	-	28×28×96	-
Conv 2	256	5×5	1	2	28×28×256	RELU
Max Pool 2	-	3×3	2	-	14×14×256	-
Conv 3	384	3×3	1	1	14×14×384	RELU
Conv 4	384	3×3	1	1	14×14×384	RELU
Conv 5	256	3×3	1	1	14×14×256	RELU
Max Pool 3	-	3×3	2	-	7×7×256	-
Dropout 1	Rate=0.5	-	-	-	7×7×256	-
Fully Connected 1	-	-	-	-	4096	RELU

Dropout 2	Rate=0.5	-	-	-	4096	-
Fully Connected 2	-	-	-	-	4096	RELU
Fully Connected 3	-	-	-	-	2	Softmax

layer: يقصد به نوع الطبقة المستخدمة حيث تشير Conv إلى الطبقة الالتفافية و تشير Max Pool إلى طبقة التجميع و Dropout تشير إلى طبقة التسرب وتشير Fully Connected إلى طبقة الاتصال الكامل.

Filters/Neurons: يوضح هذا المعامل عدد المرشحات Filters المستخدمة في الطبقة الالتفافية، و معدل الحذف في طبقة التسرب.

Filter Size: يشير هذا المعامل إلى حجم المرشحات في كل طبقة.

Stride: يقصد به عدد الخطوات التي يتحركها المرشح.

Padding: هذا المعامل يشير إلى مقدار الحشو الذي سيضاف للصورة.

Size Of Feature Map: حجم خريطة السمات هو معامل يوضح المخرجات الناتجة من كل طبقة في النموذج.

Activation Function: يقصد به وظيفة التنشيط المستخدمة.

بعد عملية بناء النموذج توجد مجموعة من المتغيرات المهمة التي يجب تحديدها قبل البدء في التدريب و هي:

Epoch : المقصود به عدد مرات تدريب واختبار النموذج، في هذا البحث تم تعينه بقيمة 50 أي أنه سيتم تدريب النموذج على مجموعة بيانات التدريب واختباره على مجموعة بيانات الاختبار خمسين مرة، تم بعد ذلك تغيره في آخر تجربة إلى 100 و ذلك كخطوة نهائية لتحسين و اعتماد النموذج.
Patch Size: المقصود به حجم الدفعة، حيث تم تقسيم كل مجموعة بيانات إلى دفعات و تم تدريب النموذج على الدفعات واحدة تلوى الأخرى، تم تعيين Patch Size بقيمة 32، كلما زاد حجم الدفعة كلما زادت مساحة الذاكرة المستخدمة للتدريب.

Steps_Per_Epoch: يقصد به عدد الدفعات في كل من مجموعة التدريب و الاختبار و يتم حسابها عن طريق تقسيم عدد العينات في كل مجموعة بيانات على حجم الدفعة.

بعد بناء النموذج و تحديد المتغيرات المهمة تبدأ مرحلة تدريب النموذج، يتم تمرير مجموعة بيانات التدريب للنموذج و التي تحتوي على فئتي الأورام الحميدة و الخبيثة و يقوم النموذج في الطبقات الالتفافية باستخراج السمات و الخصائص المميزة لكل عينة ومن ثم يتم تمريرها إلى طبقات الاتصال الكامل ليتعلم و يتدرب عليها، يتم تدريب النموذج على مجموعة بيانات التدريب عدة مرات ليحسن من أداءه.

5.1.3 تقييم النموذج

يتم في هذه المرحلة تقييم أداء النموذج المستخدم من خلال مجموعة من المقاييس، توجد العديد من المقاييس بعضها يستخدم لتقييم النموذج استنادا على قدرته في التعلم من مجموعة بيانات التدريب، و الآخر يستخدم مجموعة بيانات الاختبار لمعرفة أداءه عند التعامل مع بيانات جديدة لم يتدرب عليها سابقا، في هذا البحث تم استخدام المقاييس التالية لتقييم نموذج Alexnet المستخدم:

- Train_Accuracy: دقة التدريب تستخدم لقياس دقة النموذج على مجموعة بيانات التدريب و تمثل عدد الصور التي يتنبأ بها النموذج بشكل صحيح بالنسبة إلى القيم الحقيقة لمجموعة بيانات.

- Train Loss: خطأ التدريب هو مقياس يستخدم لتقييم مدى ملائمة النموذج من خلال تقيم الخطأ الذي ينتجه عند تدريبه على مجموعة بيانات التدريب، و لمعرفة قيمة الخطأ الناتج يتم استخدام وظيفة الخسارة Loss Function لحساب الكمية التي يجب أن يسعى النموذج لتقليلها أثناء التدريب و التي تستخدم أيضا في ضبط الأوزان لتحسين أداء النموذج، توجد العديد من وظائف الخسارة تختلف في طريقة حساب الخطأ حسب المهمة التي تستخدم لأجلها، في هذا البحث تم استخدام أحد وظائف الإنتروبيا المتقاطعة Cross_Entropy و هي الوظيفة Categorical_Cross_Entropy و التي تستخدم لحساب قيمة الخطأ للنموذج عند التعامل مع مهام التصنيف الثنائي أو المتعدد، و تستخدم بالتحديد عندما تكون وظيفة التنشيط المستخدمة في أخر طبقة للنموذج هي Softmax ، حيث تعطى القيمة 1 للفئة الحقيقية و 0 لبقية الفئات و من ثم تتم عملية حساب الخطأ الناتج لكل عينة كالتالي:

$$Loss = -\sum_{i=1} y_i \; log \; (y\hat{}_i)$$

y_i تشير إلى قيمة العدد الصحيح الذي تم إعطاءه لكل فئة، و $\hat{y}_i$ تشير إلى القيمة التي تنبأ بها النموذج، ويتم حساب إجمالي الخطأ للنموذج خلال كل مرحلة من مراحل التدريب عن طريق حساب متوسط الأخطاء الناتج لكل عينات التدريب.

- Val_Accuracy: دقة الاختبار تستخدم لقياس دقة النموذج عند إعطاءه مجموعة صور لم يتدرب عليها مسبقا، و تمثل إجمالي عدد الصور التي يتنبأ بها النموذج بشكل صحيح مقارنة بالقيم الحقيقة لمجموعة بيانات الاختبار.
- Val_Loss: يستخدم خطأ الاختبار لتقييم دقة النموذج من خلال تقيم الخطأ الذي ينتجه عند التعامل مع مجموعة بيانات الاختبار، يتم استخدام نفس وظيفة الخسارة المستخدمة في مجموعة بيانات التدريب، على عكس بيانات التدريب تستخدم قيمة خطأ الاختبار فقط لتقييم النموذج ولا تستخدم في ضبط أوزان النموذج.

الشكل التالي يوضح المنحنيات التي يتم رسمها لمقاييس التقييم السابقة والتي توضح أداء النموذج بعد كل مرحلة تدريب Epoch.

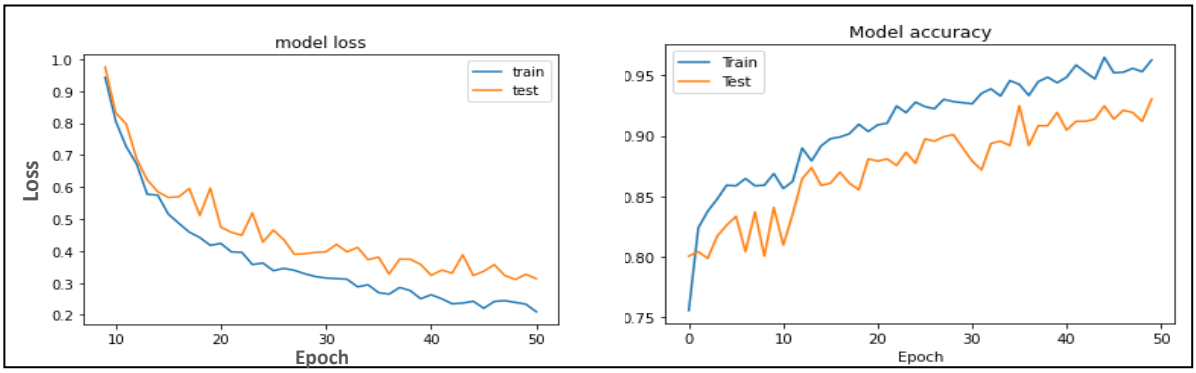

شكل (4.3) يوضح منحنيات تقييم أداء النموذج

توضح المنحنيات التي على اليمين في الشكل (4.3) الدقة التي يتم الحصول عليها بالنسبة لعدد مرات تدريب النموذج، حيث تشير الأرقام على الخط العمودي إلى نسبة دقة النموذج و تشير الأرقام على الخط الأفقي إلى عدد مرات تدريب النموذج، و المنحنيات التي على اليسار تشير إلى معدل الخطأ الناتج بعد كل مرحلة تدريب متمثل في الأرقام على الخط العمودي، المنحنيات التي تحمل اللون الأزرق تشير إلى نتائج مجموعة بيانات التدريب والمنحنيات التي باللون البرتقالي تشير إلى نتائج مجموعة بيانات الاختبار.

- مصفوفة الارتباك Confusion Matrix: مصفوفة الارتباك هي ملخص لنتائج تنبؤ النموذج بعد الانتهاء من تدريبه بشكل كامل، تستخدم لتلخيص عدد التنبؤات الصحيحة و الغير صحيحة التي تنبأ بها النموذج لكل فئة، يمثل كل عمود القيمة المتوقعة و يمثل كل سطر الفئة الفعلية، تحتوي مصفوفة الارتباك على أربعة عناصر و هي كالتالي:

True Positive (TP) : القيمة التنبئية الإيجابية الصحيحة، و تعني عدد الصور التي تنبأ بها النموذج على أنها إيجابية و هي تنتمي للفئة الايجابية.

False Positive (FP) : القيمة التنبئية الإيجابية الخاطئة، و تعني عدد الصور التي تنبأ بها النموذج على أنها سلبية و هي تنتمي للفئة الايجابية.

True Negative (TN) : القيمة التنبئية السلبية الصحيحة، و تعني عدد الصور التي تنبأ بها النموذج على أنها سلبية و هي تنتمي للفئة السلبية.

False Negative (FN): القيمة التنبئية السلبية الخاطئة، و تعني عدد الصور التي تنبأ بها النموذج على أنها إيجابية و هي تنتمي للفئة السلبية.

جدول (4.3) يوضح مصفوفة الارتباك

	التوقع الإيجابي	التوقع السلبي
الفئة الإيجابية	TP	FP
الفئة السلبية	FN	TN

وبالاعتماد على القيم التي يتم الحصول عليها من مصفوفة الارتباك، يمكننا حساب مجموعة من المقاييس الأخرى و التي تعكس أداء النموذج بشكل عام و كذلك أداءه بالنسبة لكل فئة، و المقاييس هي كالتالي:

- الدقة Accuracy: هي نسبة جميع الفئات المتوقعة بشكل صحيح بالنسبة للعدد الإجمالي للبيانات، ويتم حسابها كالتالي:

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

- الإحكام Precision: هي نسبة توقع النموذج للفئة بشكل صحيح نسبة إلى إجمالي عدد البيانات في تلك الفئة، و تحسب كالتالي:

$$Precision = \frac{TN}{TN + FN} \text{ أو } \frac{TP}{TP + FP}$$

- الحساسية Recall: هو نسبة الفئة المتوقعة بشكل صحيح نسبة إلى جميع الأمثلة المتوقعة لتلك الفئة، و يتم حسابها كالتالي:

$$Recall = \frac{TN}{TN + FP} \text{ أو } \frac{TP}{TP + FN}$$

- F1- score: تجمع درجة F1 بين الدقة و استدعاء المصنف في مقياس واحد عن طريق أخذ الوسط التوافقي لهما، و تحسب كالتالي:

$$\text{F1} - \text{score} = \frac{2 \times precision \times recall}{precision + recall}$$

6.1.3 تحسين النموذج

بعد تدريب واختبار النموذج عدة مرات تم من خلال نتائج التقييم دراسة العوامل و المتغيرات التي أثرت على دقته، و من خلال هذه العوامل تم اقتراح و تطبيق الحلول التي من شأنها تحسين أداء النموذج و إعادة تدريبه من جديد ودراسة مدى تأثير الحلول المقترحة على النتائج، سيتم توضيح التقنيات و الأدوات المستخدمة لتحسين النموذج بعد تدريبه و تقييم أدائه في الفصل الرابع.

2.3 منصة العمل

في هذا البحث تم الاعتماد على أكثر من منصة عمل تدعم لغة python و هي لغة البرمجة المستخدمة في هذا البحث، و ذلك لوجود اختلافات في الميزات و الخدمات التي تقدمها كل منصة عمل.

Colaboratory 1.2.3

هو مشروع بحثي مفتوح المصدر أصدرته شركة google يمكن الوصول إليه عن طريق الإنترنت باستخدام المتصفح، تم تصميمه لمساعدة المستخدمين على تطوير المشاريع الخاصة بمجال تعلم الآلة و التعلم العميق و مشاريع تحليل البيانات التي تتطلب موارد و أجهزة ذات قدرات عالية، يوفر colab مساحة عمل تطويرية تمكن المستخدمين من بناء مشاريعهم و مشاركتها بشكل مجاني، يدعم لغة python و لغة R و يمنح الوصول إلى ذاكرة وصول عشوائي RAM بقدرات عالية و كذلك استخدام وحدة معالجة الرسومات GPU و التي تعتبر أسرع في أداء المهام التي تتطلب قدرا كبيرا من الذاكرة و المعالجات مقارنة بالقدرات المحدودة لأجهزة الكمبيوتر الشخصي، الوقت المسموح للكتابة على colab هو 12 ساعة متواصلة في اليوم، يمكن للمستخدم بسهولة استخدام مجموعة واسعة من منصات العمل و المكتبات بشكل مباشر دون الحاجة لتثبيتها، عند الانتهاء من تطوير المشروع فإنه يخزن في السحابة ليستطيع المستخدم الوصول إليه في أي وقت و من أي جهاز باستخدام حسابه الخاص [25].

kaggle 2.2.3

هو عبارة عن منصة مفتوحة المصدر يمكن الوصول إليه عبر الإنترنت تملكه شركة google، يشبه colab في العديد من المزايا من حيث اللغة التي يدعمها و الموارد التي يوفرها، يكمن الاختلاف في أن kaggle يسمح للمستخدم الوصول إلى وحدة معالجة الرسومات GPU لمدة 30 ساعة في الأسبوع، و الوصول إلى وحدة معالجة الموتر TPU لمدة 20 ساعة في الأسبوع، و يتميز كذلك بأنه يوفر العديد من مجموعات البيانات التي تستخدم في مشاريع التعلم العميق يمكن للمستخدم الوصول إليها بكل سهولة و يمكنه أيضا تحميل مجموعة البيانات الخاصة به و مشاركتها مع الأخرين [26].

3.3 المكتبات والأدوات المستخدمة

في هذا البحث تم استخدام عدد من المكتبات و الأدوات python منها:

TensorFlow: منصة مفتوحة المصدر لتنفيذ و تدريب و نشر نماذج التعلم الآلي، تحتوي على مجموعة واسعة من المكتبات و الأدوات الجاهزة.

Keras: مكتبة مفتوحة المصدر تستخدم لتنفيذ بنى الشبكات العصبية التي تعمل على وحدة معالجة الرسومات.

Matplotlib: هي مكتبة شاملة تستخدم في إنشاء الرسوم البيانية و الصور التفاعلية.

Numpy: هي حزمة أساسية للتعامل مع المصفوفات في لغة python ، تستخدم للتعامل مع المصفوفات الكبيرة و الحقول متعددة المستوى.

Os: تعتبر من أهم المكتبات في لغة python التي تستخدم لأداء الوظائف المتعلقة بنظام التشغيل.

Scikit-learn: هي مكتبة رئيسية للغة برمجة python تستخدم في مشاريع تعلم الآلة و تحتوي على أغلب خوارزميات التعلم الألي بما في ذلك الخوارزميات الرياضية والإحصائية.

الفصل الرابع
النتائج والمناقشة

4. المقدمة

يحتوي هذا الفصل على التجارب المختلفة التي تم إجرائها لتدريب النموذج بعد خطوة المعالجة المسبقة و إعادة ترتيب مجموعة البيانات و الخطوات الأخرى التي تم توضيحها في المنهجية، و يحتوي أيضا على النتائج المتحصل عليها و مناقشتها، حيث تم تقسيم التجارب إلى خمسة أجزاء، كل جزء يحتوي على تجربة واحدة، أو أكثر من تجربة تم إجرائها بالتوازي، تم تقييم نتائج النموذج بعد كل تجربة باستخدام جميع مقاييس التقييم المذكورة و ذلك لتقييم أداءه من جميع الجوانب، ابتداء من التجربة الأولى و التي تتضمن تدريب النموذج على البيانات مباشرة دون إجراء أي خطوات تحسينية، و انتهاء بالتجربة الخامسة و التي تحتوي على النتائج النهائية التي تم اعتمادها بعد إجراء مجموعة من الخطوات التحسينية، و هي كالتالي:

- التجربة الأولى
  - التدريب الأولي للنموذج.
- التجربة الثانية
  - التدريب باستخدام الزيادة الافتراضية للبيانات Data Augmentation.
  - التدريب بعد الموازنة باستخدام Undersampling.
  - التدريب بعد الموازنة باستخدام Oversampling.
- التجربة الثالثة
  - الدمج بين Data Augmentation و Undersampling.
  - الدمج بين Data Augmentation و Oversampling.
- التجربة الرابعة
  - التدريب باستخدام تنظيم الأوزان Weights Regularization.
- التجربة الخامسة
  - التدريب بعد زيادة عدد Epoch.

1.4 التجربة الأولى

تم في هذا الجزء تدريب النموذج على مجموعة البيانات بعد إجراء الخطوات التي تم توضيحها في المنهجية، دون إجراء أي خطوات تحسينية للنموذج أو التعديل على مجموعة البيانات المستخدمة، و من ثم تقييم النموذج باستخدام مقاييس التقييم و مناقشة النتائج المتحصل عليها.

1.1.4 التدريب الاولي للنموذج

بعد تدريب النموذج و بالاعتماد على مقاييس التقييم المستخدمة تم الحصول على النتائج التالية:

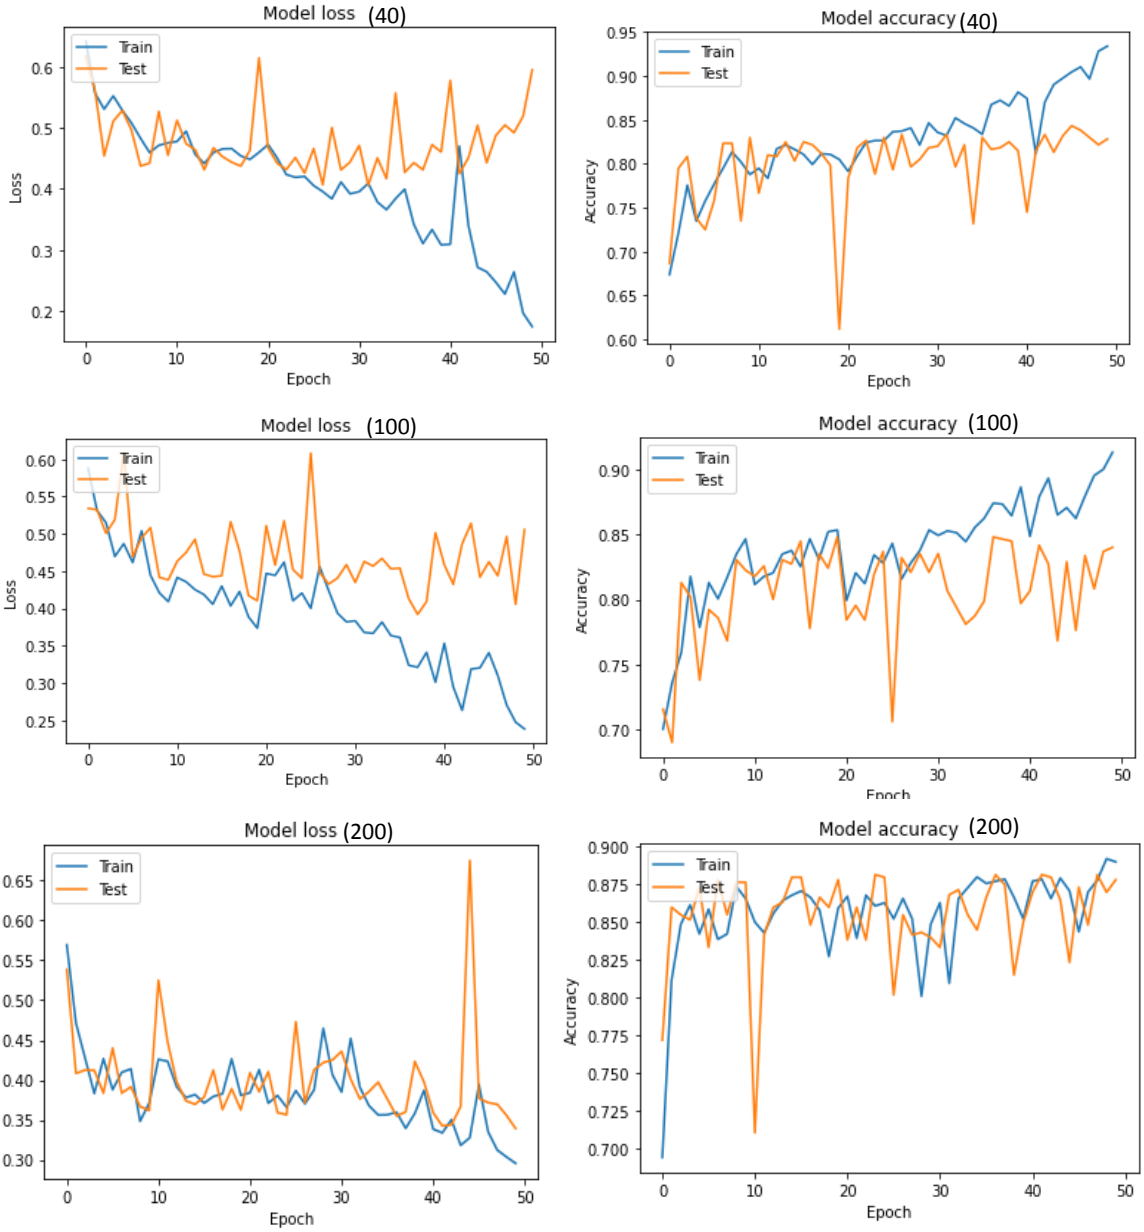

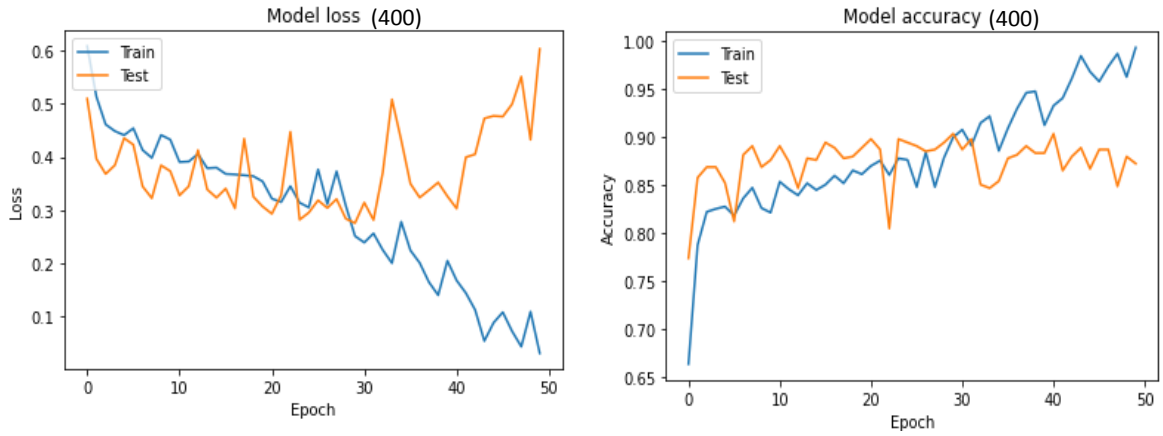

شكل (1.4) يوضح نسبة الدقة ومعدل الخطأ لكل مجموعة بيانات عند إجراء التدريب الأولي للنموذج

conf_matrix data (100)

	Benign	Malignant
Benign	63	131
Malignant	143	289

conf_matrix data (40)

	Benign	Malignant
Benign	37	151
Malignant	90	322

conf_matrix data (400)

	Benign	Malignant
Benign	59	118
Malignant	124	246

conf_matrix data (200)

	Benign	Malignant
Benign	58	129
Malignant	119	299

شكل (2.4) يوضح نتائج مصفوفة الارتباك لكل مجموعة بيانات في للتدريب الأولي للنموذج

الجدول (1.4) يوضح نتائج أداء النموذج بعد التدريب الأولي

Precision	Recall	F1-score	Support	Class	Accuracy	Size	Data
20%	29%	23%	188	**Benign**	60%	600	**40**×
78%	68%	73%	412	**Malignant**			
32%	31%	32%	194	**Benign**	56%	626	**100**×
67%	69%	68%	432	**Malignant**			
31%	33%	32%	187	**Benign**	59%	605	**200**×
72%	70%	71%	418	**Malignant**			
33%	32%	33%	177	**Benign**	56%	547	**400**×
66%	68%	67%	370	**Malignant**			

توضح المنحنيات التي على اليمين في الشكل (1.4) نسبة الدقة التي تم الحصول عليها بعد إجراء التجربة الأولية، و المنحنيات التي على اليسار توضح معدل الخطأ الناتج بعد كل مرحلة تدريب Epoch، تشير النتائج إلى وجود فرط التخصيص Overfitting و المقصود به أن النموذج غير قادر على التعميم إذ أنه تدرب بشكل جيد أثناء مرحلة التدريب و لكن عند اختباره على بيانات جديدة لم يتدرب عليها من قبل و المتمثلة في مجموعة بيانات الاختبار فإنه يعطي نتائج غير جيدة، ظهرت هذه المشكلة في مجموعات البيانات الأربعة المستخدمة رغم اختلاف خصائصها و ذلك بسبب قلة البيانات في مجموعة التدريب، حيث يوضح المنحنى الذي يمثل دقة التدريب في مجموعة البيانات (40×) ارتفاع دقة النموذج بشكل ملحوظ بعد كل مرحلة تدريب أما بالنسبة للمنحنى الذي يوضح دقة الاختبار فأنه يوضح ارتفاع نسبة الدقة حتى تصل إلى epoch 42 من ثم تضل على نفس المستوى تقريبا رغم ازدياد نسبة الدقة الخاصة بالتدريب، و كذلك بالنسبة للمنحنيات التي تشير إلى معدل الخطأ الذي ينتجه النموذج يتضح أن معدل الخطأ لمجموعة التدريب ينخفض بعد كل epoch أما معدل الخطأ لمجموعة الاختبار فإنه لا ينخفض وإنما يضل يتذبذب في مستوى معين و هو مستوى أعلى

من الخطأ الخاص بمجموعة التدريب، تتضح هذه المشاكل أيضا بالنسبة لمجموعات البيانات الأخرى، و هذا بالتحديد ما يشير اليه مصطلح overfitting.

الجدول (1.4) يحتوي على النتائج التي يتم من خلالها قياس أداء النموذج بواسطة المقاييس الموضحة و التي تم حساب قيمها عن طريق القيم الخاصة بمصفوفة الارتباك في الشكل (2.4)، توضح النتائج أن نسبة دقة النموذج للمجموعات الأربعة غير جيدة نسبيا حيث تراوحت نسبة الدقة بين 56%–60%، و هي أرقام منخفضة مقارنة بالنتائج التي حققها النموذج المستخدم في الدراسات السابقة.

و توضح مقاييس F1-score أن النموذج منحاز للفئة السلبية Malignant أكثر من الفئة الإيجابية Benign، حيث تراوحت النسبة في مجموعات البيانات الأربعة للفئات السلبية بين 67%–73%، و تراوحت نسبة الدقة للفئات الإيجابية بين 23%–33% و هي نسبة منخفضة جدا مقارنة بما حققه النموذج بالنسبة للفئات السلبية، و يرجع سبب هذا التفاوت في نسبة الدقة إلى عدم توازن الفئتين حيث أن عدد الصور في مجموعات البيانات و التي تنتمي للفئة السلبية أكثر من عدد الصور في الفئة الإيجابية وهذا ما جعل النموذج يعطي نسبة دقة أكثر للفئة السلبية.

و بناء على هذه المشاكل فإنه يتوجب علينا حلها و ذلك للتحسين من أداء النموذج، تم اقتراح مجموعة من الحلول سيتم توضيحها في الجزء الثاني.

2.4 التجربة الثانية

في هذا الجزء تم اقتراح مجموعة من الحلول للمشاكل التي تم استنتاجها من الجزء الأول و المتمثلة في مشكلة فرط التخصيص و مشكلة عدم توازن البيانات و التي أدت إلى انحياز النموذج، و بناء على النتائج التي سيتم الحصول عليها سيتم أيضا مراقبة دقة النموذج بشكل عام و معرفة مدى تأثير الحلول المقترحة عليه.

لحل مشكلة فرط التخصيص و التي حدثت بسبب قلة البيانات المستخدمة في تدريب النموذج سيتم استخدام الزيادة الافتراضية للبيانات Data Augmentation و التي تعني زيادة عدد صور مجموعة البيانات المستخدمة دون الحاجة إلى استخدام صور جديدة من خارج المجموعة، و ذلك من خلال إجراء العديد من عمليات التحويل عليها مثل التدوير و التكبير و الإزاحة و غيرها من

العمليات التي من شأنها التغيير في خصائص الصور وإنشاء صور جديدة من الصور الأصلية، و بالتالي سيصبح النموذج أكثر قدرة في التعميم على البيانات الجديدة، طريقة تحديد العمليات التي سيتم تطبيقها على الصور كانت عشوائية، لأن الغرض الأساسي منها هو التغيير في خصائص الصور بغض النظر عن العملية التي سيتم استخدامها، الجدول التالي يوضح المعاملات المستخدمة في هذا البحث و التي يشير كل منها إلى عملية من عمليات التحويل التي تم اجرائها على الصور، و القيم الخاصة بكل معامل والتوصيف لشرح وظيفة كل معامل.

جدول (2.4) يوضح معاملات Data Augmentation

المعامل	القيمة	التوصيف
Horizontal_Flip	True	تدوير الصورة أفقيا
Vertical_Flip	True	تدوير الصورة رأسيا
Featurewise_Center	True	حساب متوسط البكسلات لمجموعة البيانات ومن ثم طرح كل بكسل في كل صورة من المتوسط
Samplewise_Center	True	حساب متوسط البكسلات لكل صورة على حدة و طرحه منها
Featurewise_Std_Normalization	True	حساب الانحراف المعياري لكل بكسل في مجموعة البيانات ومن ثم تقسيم كل بكسل في كل صورة على الانحراف المعياري .
Samplewise_Std_Normalization	True	حساب الانحراف المعياري لكل صورة على حدة و تقسيم كل بكسل في الصورة عليه
Zca_Whitening	True	تطبيق تبييض ZCA (تحليل مكون المرحلة الصفرية)
Zca_Epsilon	1e-06	جعل قيمة إبسيلون لتبييض ZCA تساوي 1e−06
Fill_Mode	"nearest"	تعبئة الأماكن الفارغة في الصورة عند تحريكها من خلال إكمال الاماكن المفقودة وجعلها مساوية لأقرب نقطة

و لحل مشكلة عدم توازن الفئتين التي أدت إلى انحياز النموذج للفئة السلبية أكثر من الفئة الإيجابية، سيتم موازنة الفئتين في كل مجموعة من مجموعات البيانات المستخدمة و ذلك من خلال جعل الفئتين متساويتين في العدد، توجد طريقتين لموازنة الفئات و هما:

- الإفراط في أخذ العينات (Oversampling): و تعني موازنة الفئتين عن طريق زيادة العيانات في الفئة الأقلية.
- الاختزال في أخذ العينات (Undersampling): و تعني موازنة الفئتين عن طريق حذف العيانات من الفئة الأكثرية.

يتم في هذا البحث استخدام الطريقتين لتحديد أي طريقة أكثر فعالية و تعطي نتائج أفضل من غيرها، تم تنفيذ الطريقتين يدويا و ذلك بسبب أن كل فئة من مجموعة البيانات المستخدمة تحتوي على أربع أنواع من الأورام كما تم توضيح ذلك سابقا، و لذلك فإنه عند استخدام الدوال الجاهزة ستنفذ العملية بطريقة عشوائية و هذا ما يجعلها تقوم بحذف أو نسخ نوع معين أكثر من غيره، الجدول(1.3) يوضح بالتفصيل عدد الصور لكل نوع من الأورام حيث نلاحظ أن هناك أنواع معينة أكثر من غيرها و قد تتم عملية النسخ بشكل أكبر على الأنواع التي عددها أكثر و قد تتم أيضا عملية الحذف من الأنواع الأقل بشكل كبير، و عندها سيصبح هناك تغيير في التوزيع الحقيقي للأنواع و هذا ما يجعل عملية الحذف العشوائية غير مجدية، و بالتالي تم إجراء عملية الحذف و كذلك الإضافة بنسبة متساوية لكل نوع، و من الملاحظ أيضا أن عدد الصور في الفئة الأكثرية هو ضعف عدد الفئة الأقلية تقريبا في كل المجموعات، و بالتالي لتنفيذ Undersampling تم حذف نصف الفئة الاكثرية أي أنه تم الحذف بنسبة 50% و بالتالي أصبحت متساوية تقريبا للفئة الأقلية، و لتنفيذ Oversampling تمت مضاعفة الفئة الأقلية عن طريق نسخ كل الصور في الفئة، يجب التنويه أنه تم تغيير تقسيم مجموعة البيانات بعد إجراء عملية النسخ حيث تم تغييرها إلى 80% للتدريب و 20% للاختبار و ذلك لأن عدد الصور تضاعف فبالتالي عند استخدام التقسيمة الأولى فإن عدد الصور المستخدمة لاختبار النموذج ستكون أكثر مما كانت عليه في التجارب السابقة و لأن النموذج أيضا بحاجة إلى التدريب بشكل جيد فإن التقسيمة الجديدة كافية لاختبار النموذج.

1.2.4 التدريب باستخدام الزيادة الافتراضية للبيانات Data Augmentation

النتائج المتحصل عليها بعد تدريب النموذج على البيانات التي تمت موازنتها باستخدام Data Augmentation كانت كالتالي:

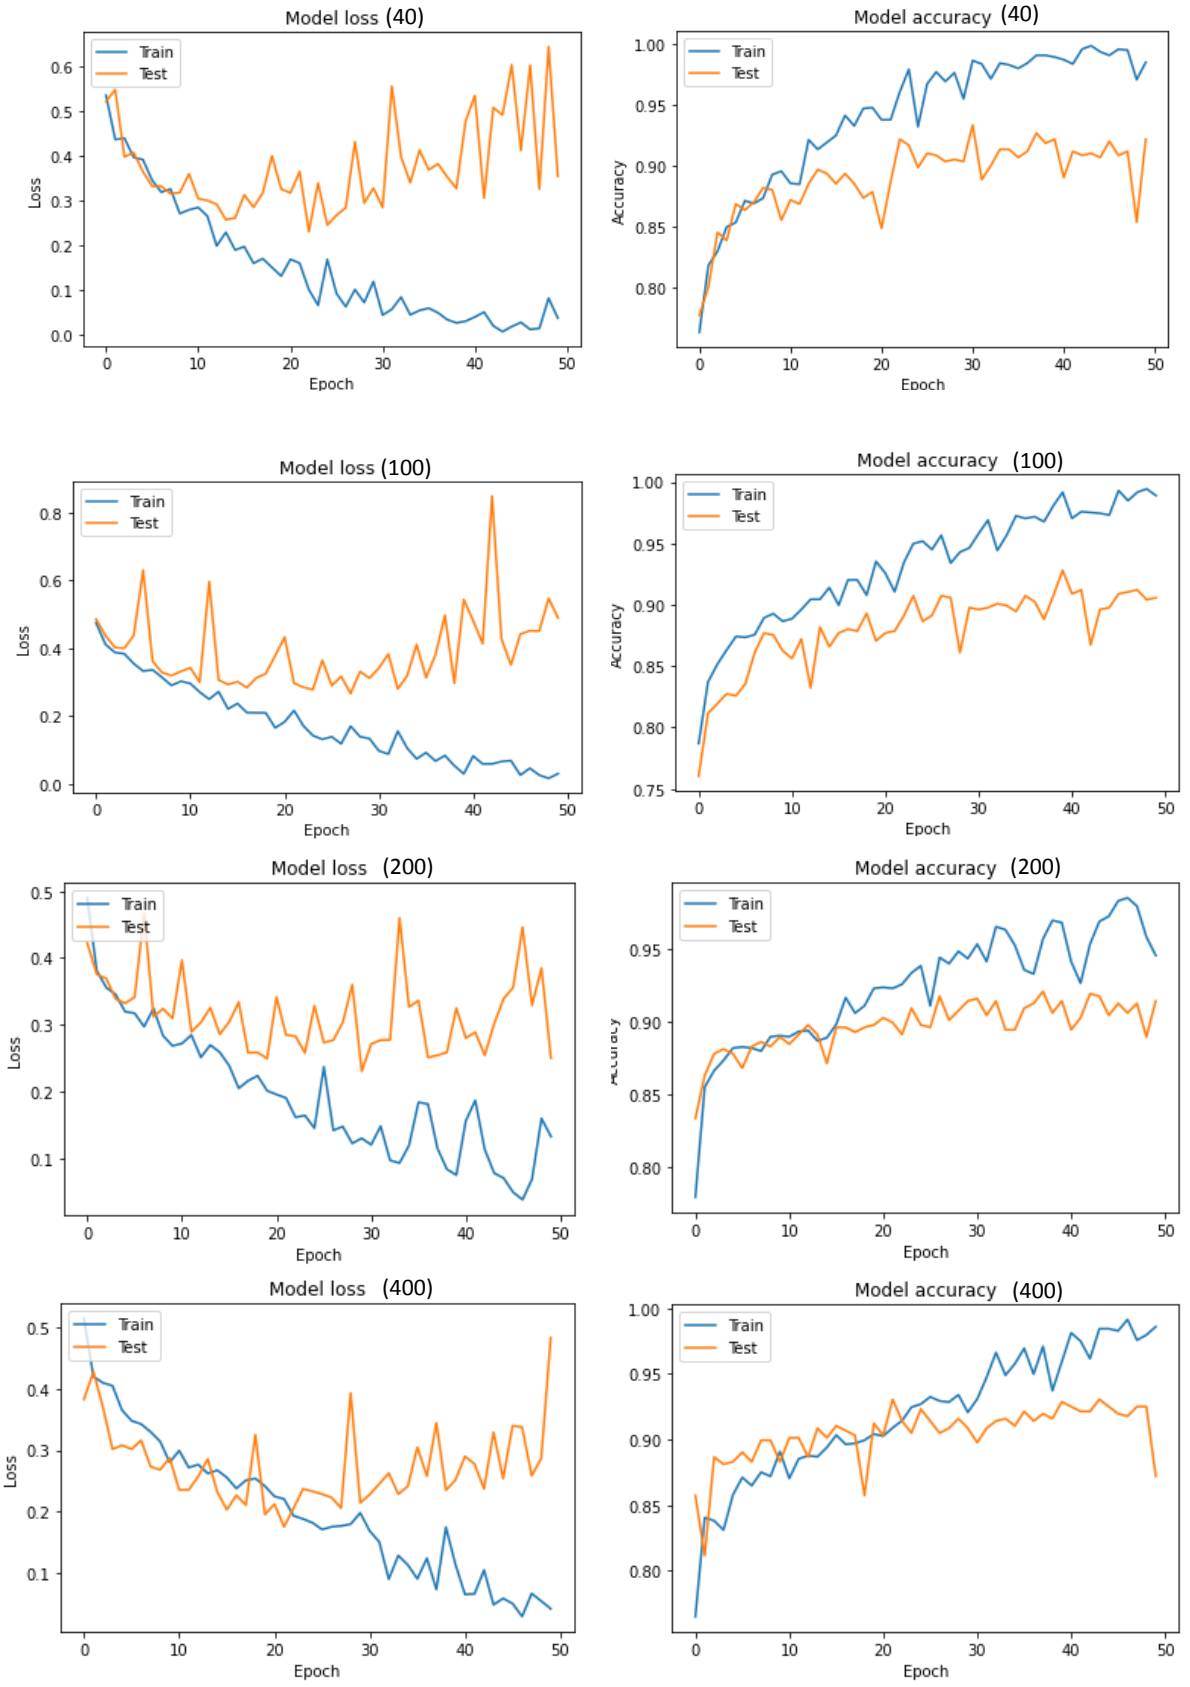

شكل (3.4) يوضح نسبة الدقة ومعدل الخطأ لكل مجموعة بيانات بعد تطبيق Data Augmentation

conf_matrix data (100)

	Benign	Malignant
Benign	153	41
Malignant	16	416

conf_matrix data (40)

	Benign	Malignant
Benign	159	29
Malignant	15	397

conf_matrix data (400)

	Benign	malignant
Benign	104	73
Malignant	6	364

conf_matrix data (200)

	Benign	Malignant
Benign	166	21
Malignant	36	382

شكل (4.4) يوضح نتائج مصفوفة الارتباك لكل مجموعة بيانات بعد تطبيق Data Augmentation

الجدول (3.4) يوضح نتائج أداء النموذج بعد تطبيق Data Augmentation

Precision	**Recall**	**F1-score**	**Support**	**Class**	**Accuracy**	**Size**	**Data**
85%	91%	88%	188	**benign**	93%	600	**40×**
96%	93%	95%	412	**malignant**			
79%	91%	84%	194	**benign**	91%	626	**100×**
96%	91%	94%	432	**malignant**			
89%	82%	85%	187	**benign**	91%	605	**200×**
91%	95%	93%	418	**malignant**			
59%	95%	72%	177	**benign**	86%	547	**400×**
98%	83%	90%	370	**malignant**			

توضح نتائج المنحنيات التي على اليمين في الشكل (3.4) تحسن ملحوظ في النموذج بعد تطبيق الزيادة الافتراضية للبيانات، حيث يوجد ارتفاع في نسبة دقة التدريب و كذلك الاختبار، و تشير النتائج أيضا بأنه يجود تحسن في أداء النموذج بعد كل مرحلة تدريب Epoch، حيث ارتفعت نسبة الدقة لكل من التدريب والاختبار بشكل تدريجي و منتظم على عكس ما أظهرته نتائج التجربة الأولية، و من الملاحظ كذلك أن الفجوة بين دقة التدريب والاختبار قلت أي أن النموذج أصبح أكثر قدرة في التعميم على البيانات الجديدة، أما بالنسبة للمنحنيات الموجودة على اليسار و التي تشير إلى معدلات الخطأ الناتج للنموذج تشير إلى أنه يوجد انخفاض في معدل الخطأ النتائج من عملية التدريب فقط و لا يوجد تحسن في معدل الخطأ لعملية الاختبار.

ومن خلال الجدول (3.4) نستنتج أن نسبة الدقة ارتفعت بشكل كبير لكل مجموعة من مجموعات البيانات حيث كانت في التجربة الأولية تساوي: (56% ، 59% ، 59% ، 60%) فأصبحت تساوي: (93%،91%،91%،86%)، وبما أن نسبة الدقة لا تعكس حقيقة أداء النموذج عندما تكون البيانات غير متوازنة تم قياس الأداء من خلال المقاييس الأخرى المتمثلة في Recall و Precision و F1-score، من خلال هذه المقاييس تبين أن انحياز النموذج للفئة الأكثرية تناقص بشكل كبير و أصبحت المقاييس لكل من الفئة السلبية و الفئة الايجابية متقاربة بشكل أفضل من النتائج السابقة.

2.2.4 التدريب بعد موازنة البيانات باستخدام Undersampling

النتائج المتحصل عليها بعد تدريب النموذج على البيانات التي تمت موازنتها باستخدام Undersampling كانت كالتالي:

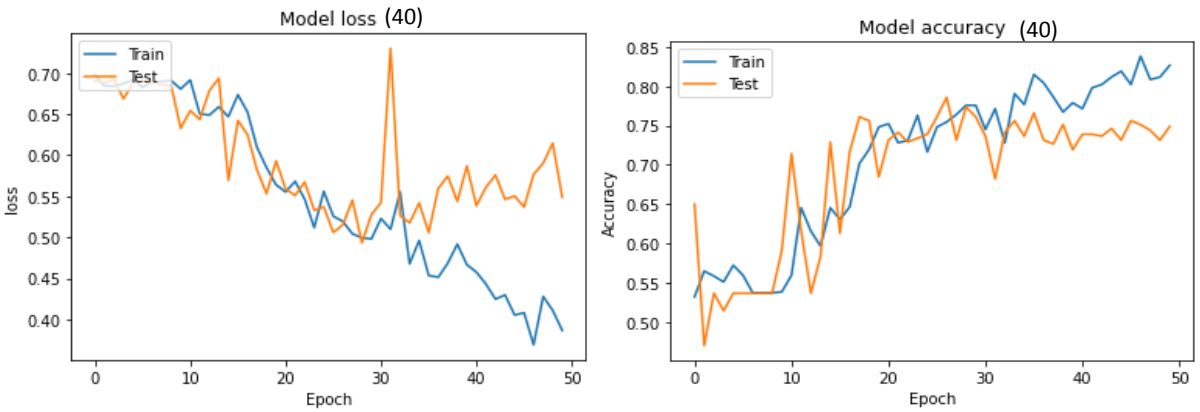

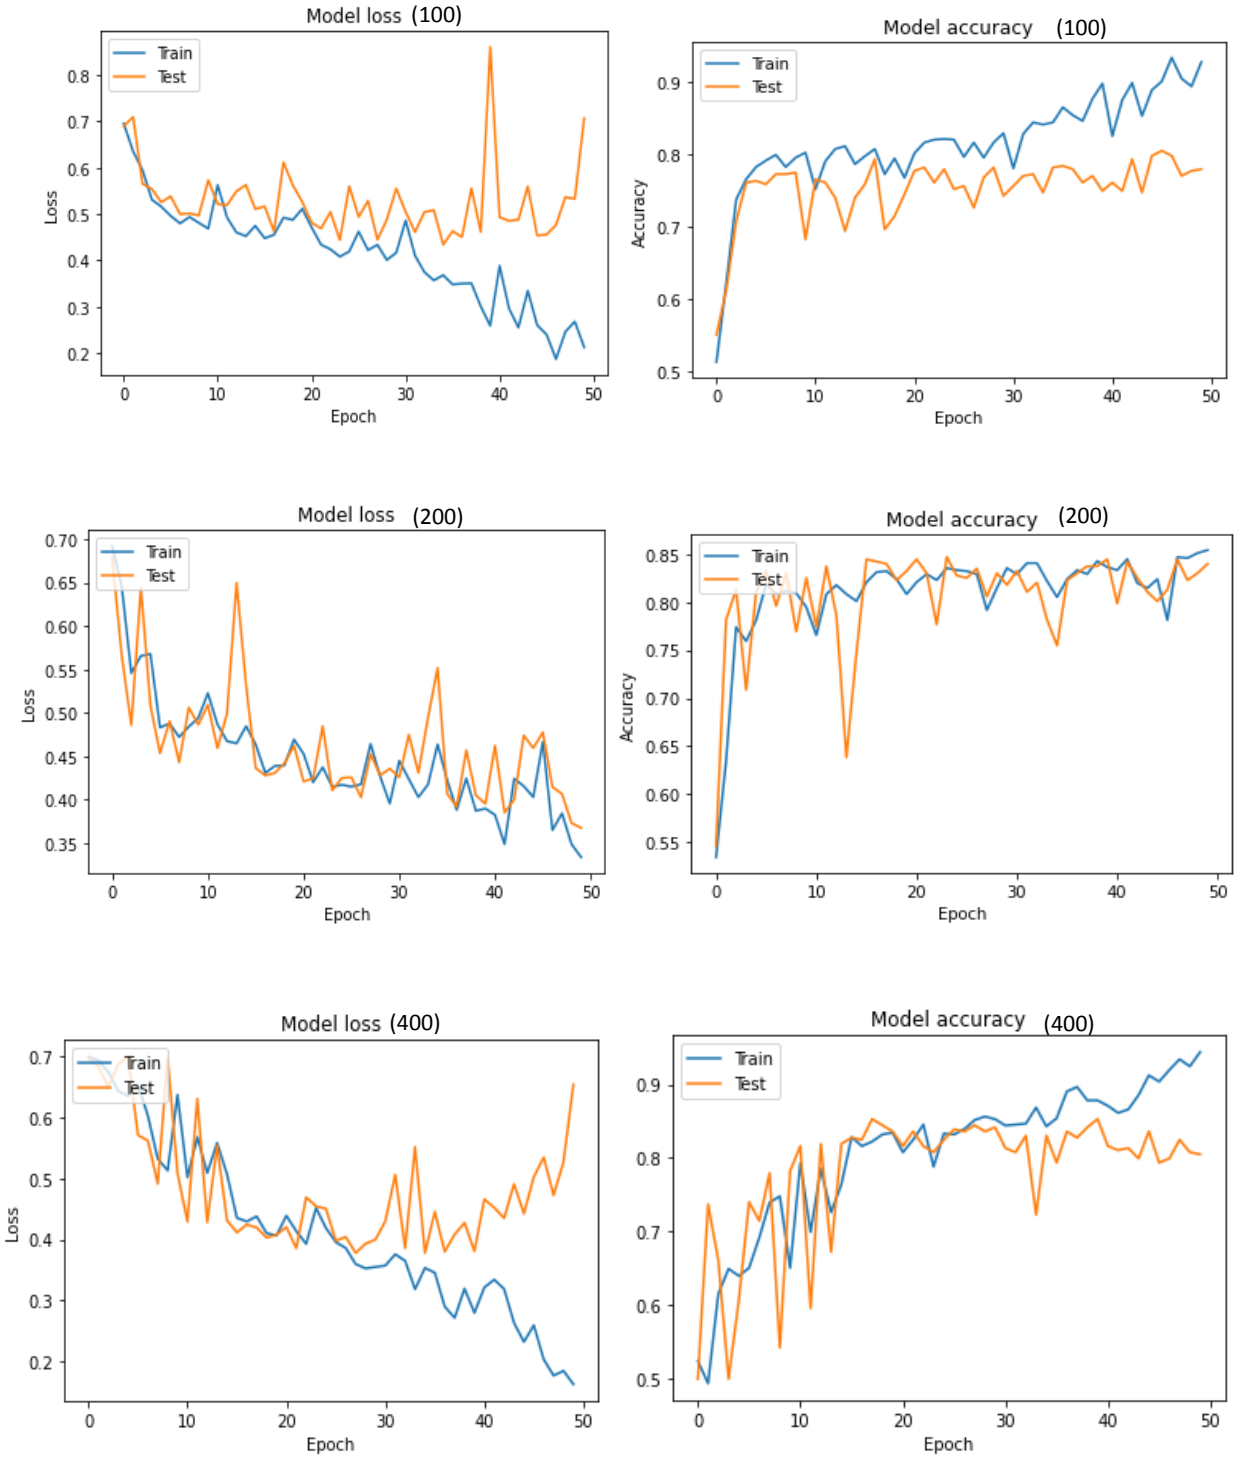

شكل (5.4) يوضح نسبة الدقة ومعدل الخطأ لكل مجموعة بيانات بعد تطبيق Undersampling

conf_matrix data (100)

	Benign	Malignant
Benign	104	90
Malignant	101	137

conf_matrix data (40)

	Benign	Malignant
Benign	92	96
Malignant	110	108

conf_matrix data (400)

	Benign	Malignant
Benign	101	76
Malignant	107	70

conf_matrix data (200)

	Benign	Malignant
Benign	74	113
Malignant	97	128

شكل (6.4) يوضح نتائج مصفوفة الارتباك لكل مجموعة بيانات بعد تطبيق Undersampling

الجدول (4.4) يوضح نتائج أداء النموذج بعد تطبيق Undersampling

Precision	Recall	F1-score	Support	Class	Accuracy	Size	Data
49%	46%	47%	188	**Benign**	49%	524	**40×**
50%	53%	51%	218	**Malignant**			
54%	51%	52%	258	**Benign**	56%	432	**100×**
58%	60%	59%	288	**Malignant**			
40%	43%	41%	187	**Benign**	49%	412	**200×**
57%	53%	55%	225	**Malignant**			
57%	49%	52%	177	**Benign**	48%	354	**400×**
40%	48%	43%	177	**Malignant**			

توضح المقاييس في الجدول (4.4) أن انحياز النموذج أصبح أقل من السابق حيث تشير نتائج الفئتين إلى تقارب النسب لكل منها، و تشير أيضا إلى أن نسبة الدقة للنموذج انخفضت مقارنة بنتائج التجربة الأولية وكذلك انخفاضها لكل من الفئة السلبية والفئة الايجابية، وبهذا نستنتج أنه عند تطبيق Undersampling أدى ذلك إلى حل مشكلة الانحياز و لكن سبب في انخفاض نسبة الدقة في الفئتين مما أدى ذلك إلى انخفاض نسبة دقة النموذج بشكل عام.

3.2.4 التدريب بعد موازنة البيانات باستخدام Oversampling

النتائج المتحصل عليها بعد تدريب النموذج على البيانات التي تمت موازنتها باستخدام Oversampling كانت كالتالي:

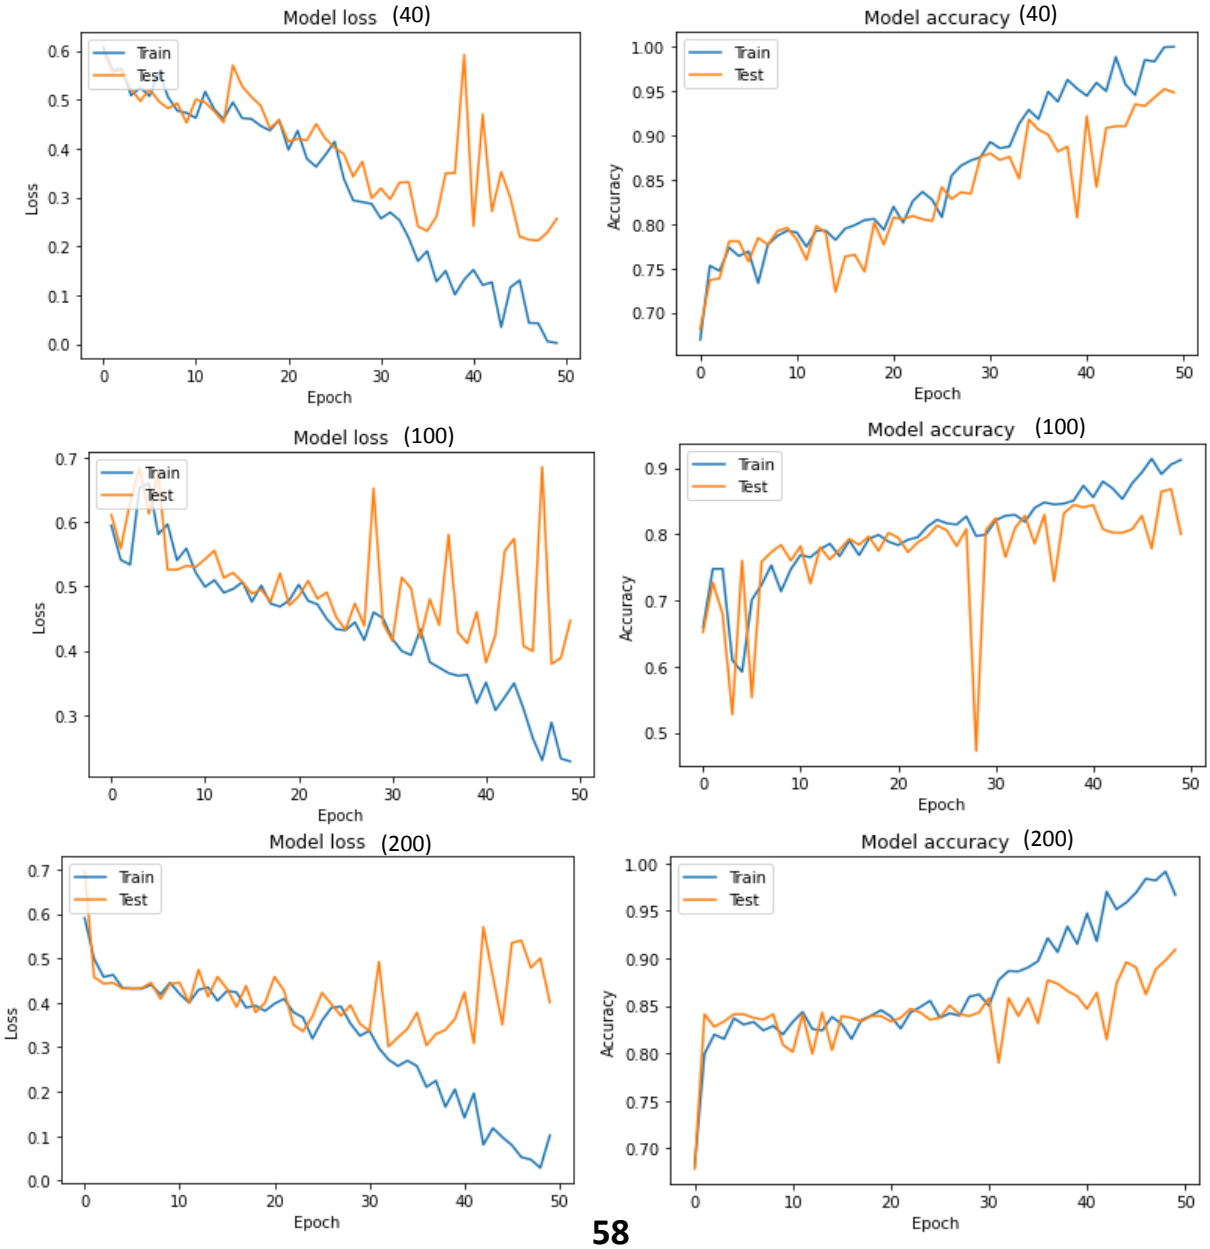

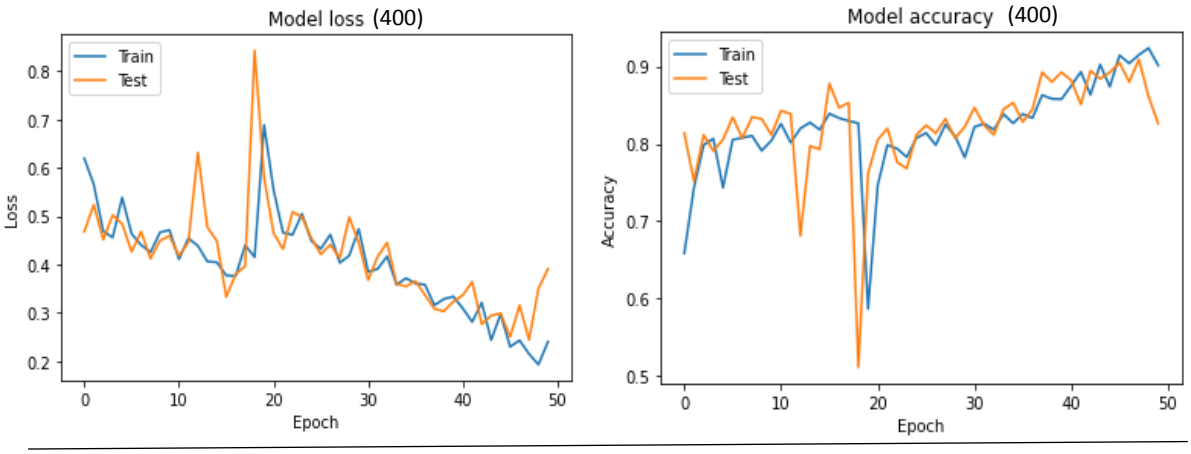

شكل (7.4) يوضح نسبة الدقة ومعدل الخطأ لكل مجموعة بيانات بعد تطبيق Oversampling

conf_matrix data(100)

	Benign	Malignant
Benign	93	165
Malignant	104	184

conf_matrix data(40)

	Benign	Malignant
Benign	119	131
Malignant	142	132

conf_matrix data(400)

	Benign	Malignant
Benign	100	136
Malignant	92	155

conf_matrix data(200)

	Benign	Malignant
Benign	124	126
Malignant	144	135

شكل (8.4) يوضح نتائج مصفوفة الارتباك لكل مجموعة بيانات بعد تطبيق Oversampling

جدول (5.4) يوضح نتائج أداء النموذج بعد تطبيق Oversampling

Precision	Recall	F1-score	Support	Class	Accuracy	Size	Data
48%	46%	47%	250	**Benign**	48%	524	**40**×
48%	50%	49%	274	**Malignant**			
36%	47%	41%	258	**Benign**	51%	546	**100**×
64%	53%	58%	288	**Malignant**			
50%	46%	48%	250	**Benign**	49%	529	**200**×
48%	52%	50%	279	**Malignant**			
42%	52%	47%	236	**Benign**	53%	483	**400**×
63%	53%	58%	247	**Malignant**			

توضح المقاييس في الجدول (4.5) أن النتائج التي حققها النموذج عند تطبيق Oversampling أدت إلى نفس النتائج عند تطبيق Undersampling من حيث انخفاض نسبة الدقة للفئتين وانخفاضها أيضا بشكل عام، و كذلك من حيث تقليل الانحياز حيث أصبحت النسب بين الفئتين متقاربة، و لكن عند المقارنة بين الجدولين باستخدام المقاييس الخاصة لكل فئة نجد أن تفاوت النسب بين الفئتين في الجدول (4.5) أقل من تفاوت النسب في الجدول (3.5)، و بهذا نستنتج أنه عند تطبيق Oversampling لموازنة البيانات أدى ذلك إلى تقليل الانحياز بشكل أكبر مقارنة بتطبيق Undersampling.

من خلال التجارب الثلاثة التي تم إجراءها في الجزء الثاني نستنتج أنه عند تطبيق الزيادة الافتراضية للبيانات تحسن النموذج بشكل ملحوظ و أصبح أكثر قدرة على التعميم و لكن لا يزال النموذج منحاز للفئة السلبية، و عندما تمت موازنة الفئتين باستخدام الطرق المقترحة فإن انحياز النموذج أصبح أقل و لكن أدت الطرق إلى انخفاض نسبة الدقة للنموذج في كل مجموعة من مجموعات البيانات، و بناء على هذه النتائج تم اقتراح مجموعة من الحلول سيتم توضيحها في الجزء الثالث.

3.4 التجربة الثالثة

من خلال النتائج التي تم الحصول عليها في الجزء الثاني سيتم في هذا الجزء استخدام تجربتين الأولى تتمثل في الدمج بين Data Augmentation و Undersampling ، و الثانية سيتم فيها الدمج بين Data Augmentation و Oversampling، و ذلك لحل مشكلة الانحياز وفرط التخصيص معا.

1.3.4 الدمج بين Data Augmentation و UnderSampling

النتائج المتحصل عليها بعد تدريب النموذج باستخدام Data Augmentation وUnderSampling كانت كالتالي:

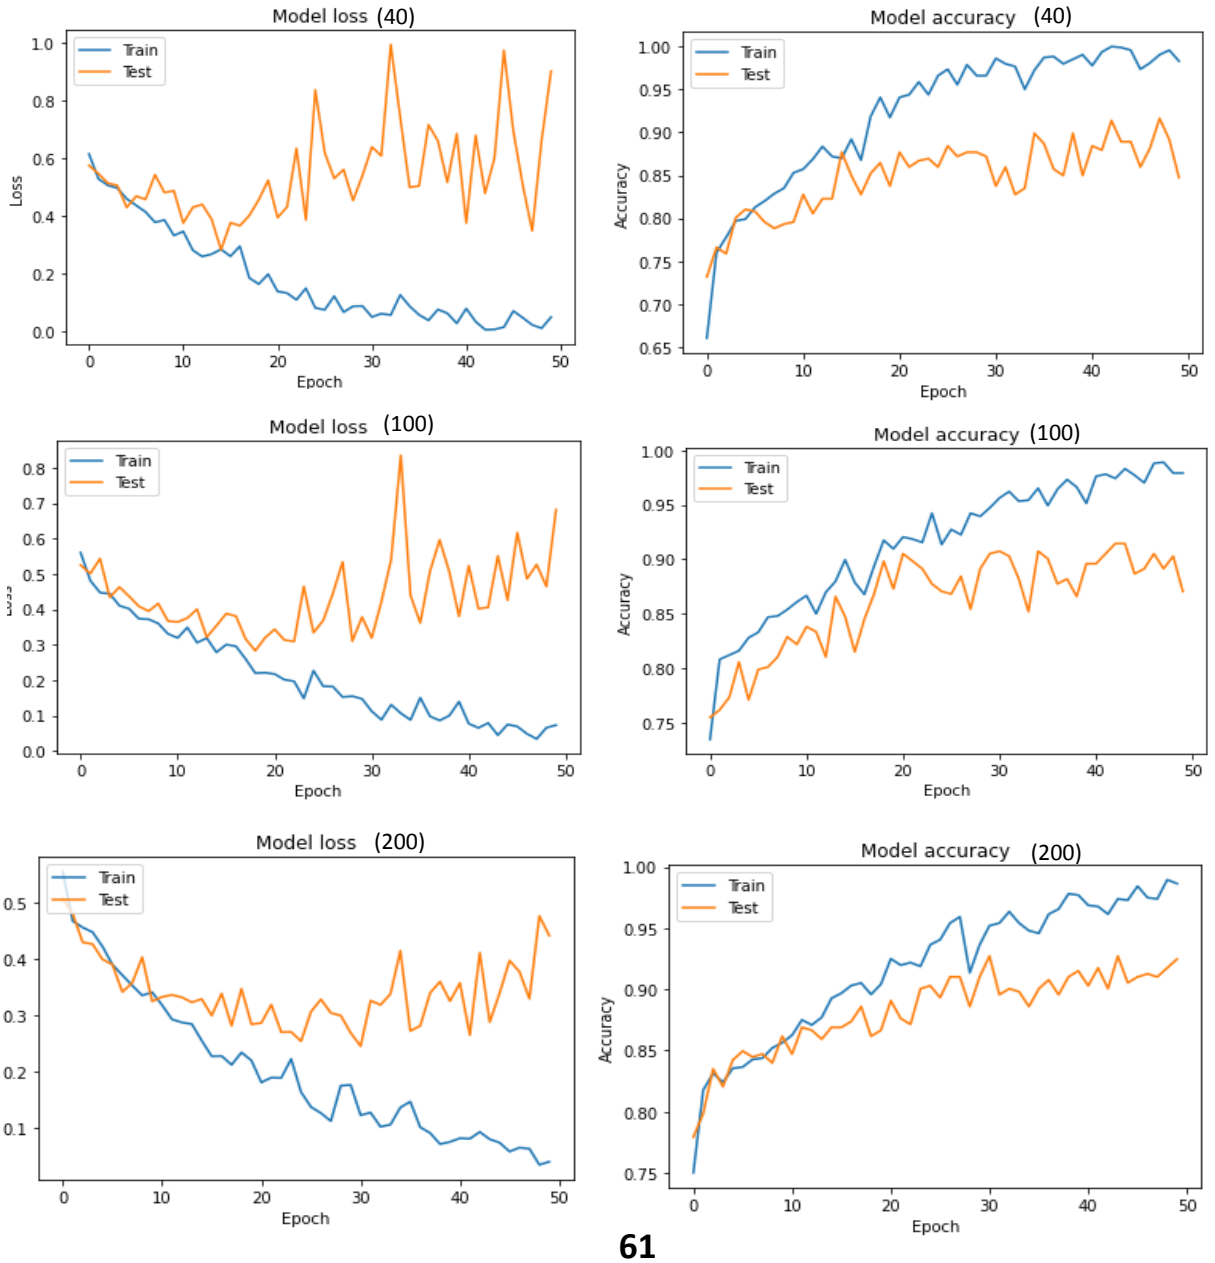

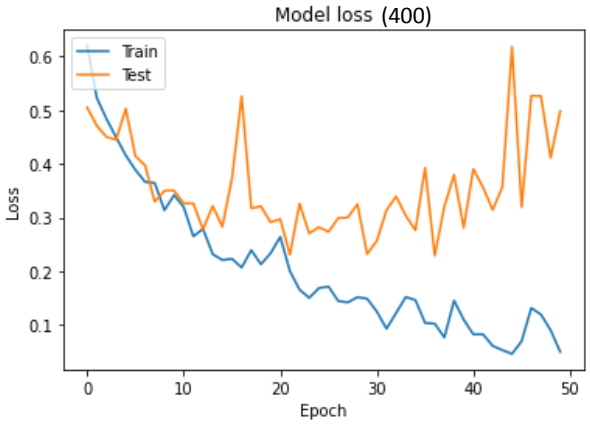

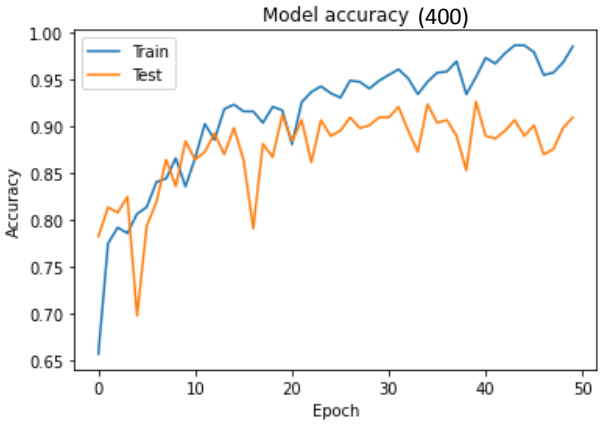

شكل (9.4) يوضح نسبة الدقة ومعدل الخطأ لكل مجموعة بيانات بعد تطبيق Data Augmentation و Undersampling

conf_matrix data (100)

	Benign	Malignant
Benign	171	23
Malignant	27	211

conf_matrix data (40)

	Benign	Malignant
Benign	159	29
Malignant	14	204

conf_matrix data(400)

	Benign	Malignant
Benign	165	12
Malignant	21	156

conf_matrix data(200)

	Benign	Malignant
Benign	173	14
Malignant	19	206

شكل (10.4) يوضح نتائج مصفوفة الارتباك لكل مجموعة بيانات بعد تطبيق Data Augmentation و Undersampling

جدول (6.4) يوضح نتائج أداء النموذج بعد تطبيق Data Augmentation و Undersampling

Precision	Recall	F1-score	Support	Class	Accuracy	Size	Data
85%	92%	88%	188	**Benign**	89%	406	**40**×
94%	88%	90%	218	**Malignant**			
88%	86%	87%	194	**Benign**	88%	432	**100**×
89%	90%	89%	238	**Malignant**			
93%	90%	91%	187	**Benign**	92%	412	**200**×
92%	94%	93%	225	**Malignant**			
93%	89%	91%	177	**Benign**	91%	354	**400**×
88%	93%	90%	177	**Malignant**			

2.3.4 الدمج بين Data Augmentation و Oversampling

النتائج التي تحصلنا عليها بعد تدريب النموذج باستخدام Data Augmentation و Oversampling كانت كالتالي:

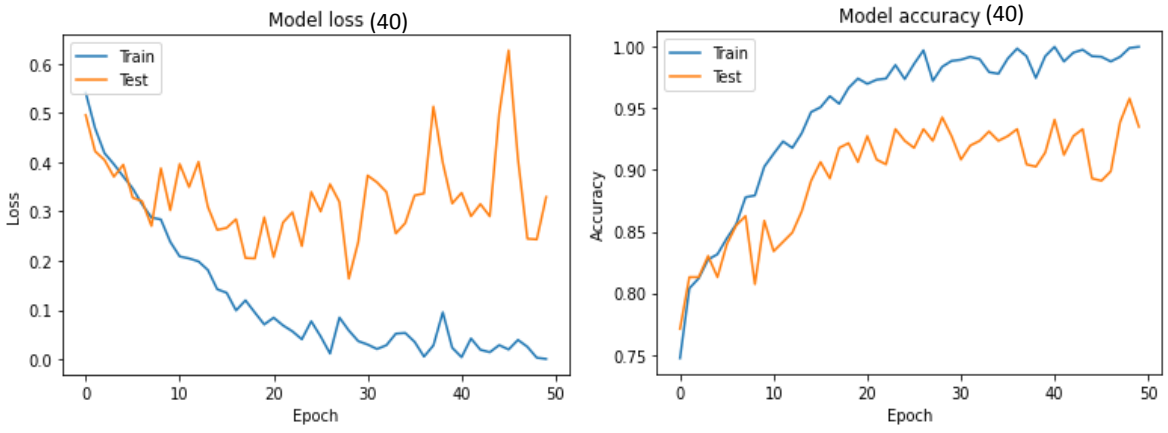

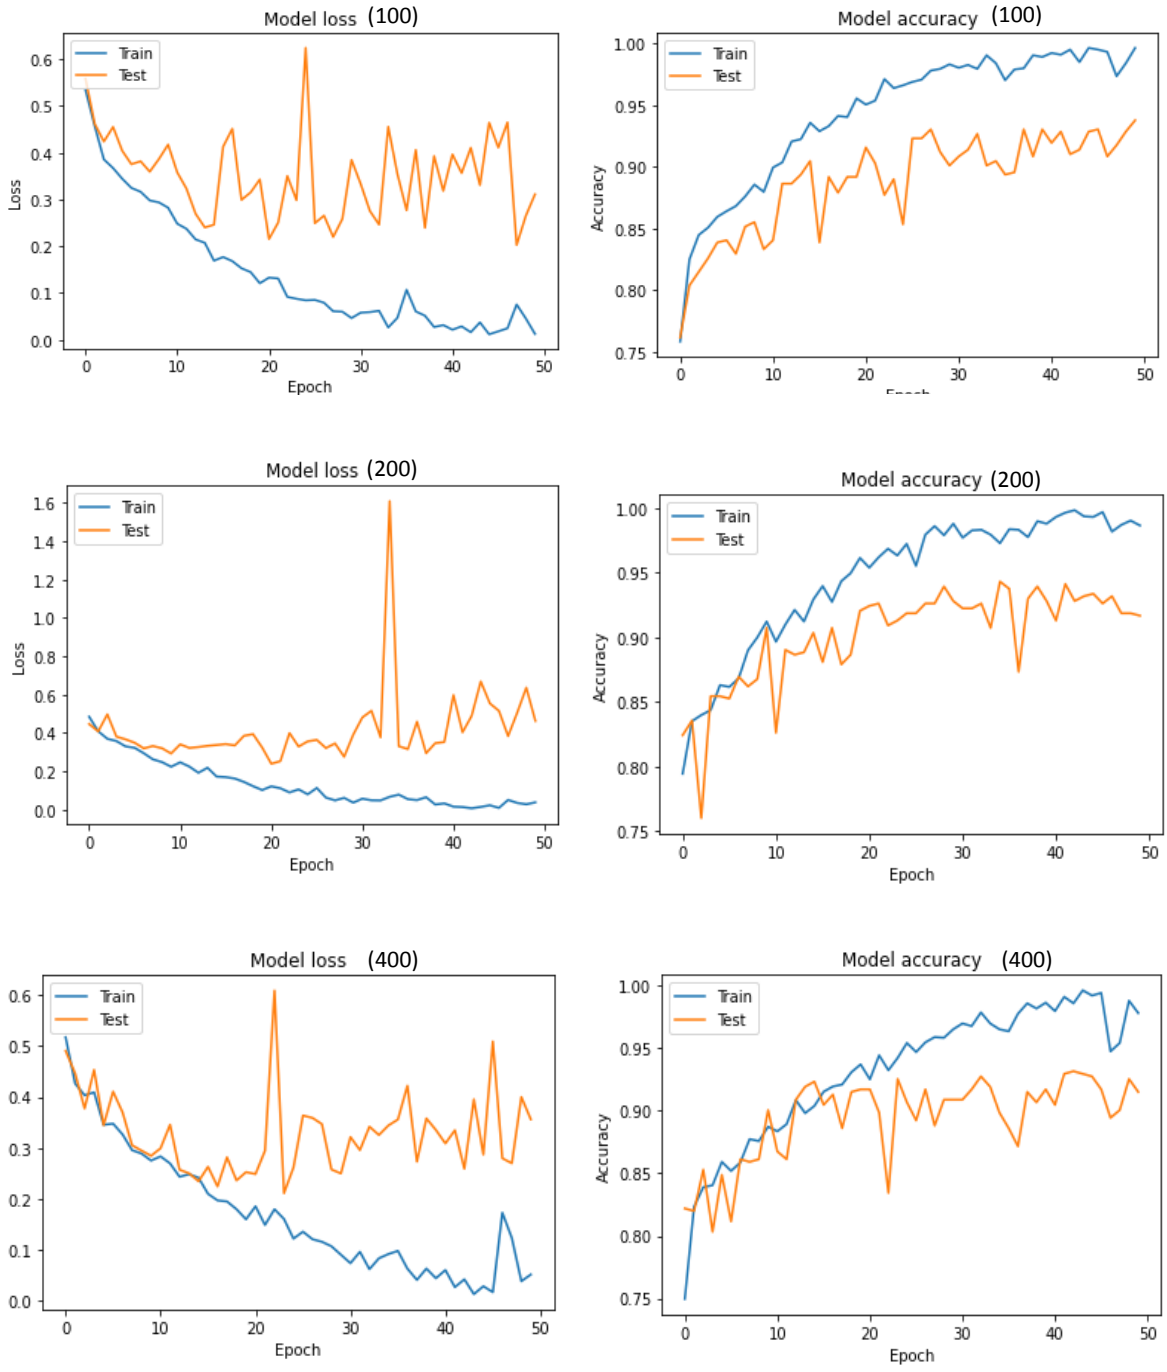

شكل (11.4) يوضح نسبة الدقة ومعدل الخطأ لكل مجموعة بيانات بعد تطبيق Data Augmentation و Oversampling

conf_matrix data (100)

	Benign	Malignant
Benign	240	18
Malignant	14	274

conf_matrix data (40)

	Benign	Malignant
Benign	232	18
Malignant	3	271

conf_matrix data (400)

	Benign	Malignant
Benign	206	30
Malignant	16	231

conf_matrix data (200)

	Benign	Malignant
Benign	220	30
Malignant	14	265

شكل (12.4) يوضح نتائج مصفوفة الارتباك لكل مجموعة بيانات بعد تطبيق Data Augmentation و Oversampling

جدول (7.4) يوضح نتائج أداء النموذج بعد تطبيق Data Augmentation و Oversampling

Precision	**Recall**	**F1-score**	**Support**	**Class**	**Accuracy**	**Size**	**Data**
93%	99%	96%	250	**benign**	96%	524	**40**×
99%	94%	96%	274	**malignant**			
93%	94%	94%	258	**benign**	94%	546	**100**×
95%	94%	94%	288	**malignant**			
88%	94%	91%	250	**benign**	92%	529	**200**×
95%	90%	92%	279	**malignant**			
87%	93%	90%	236	**benign**	90%	483	**400**×
94%	89%	91%	247	**malignant**			

توضح النتائج وجود تحسن ملحوظ في أداء النموذج لكل مجموعة من مجموعات البيانات بعد الدمج بين Data Augmentation و Undersampling و الدمج بين Data Augmentation و Oversampling حيث أظهرت المنحنيات في الشكل (9.4) و الشكل (11.4) أنه لا يوجد فرط تخصيص Overfitting أي أن الطريقتين فعالتين في تحسين النموذج و جعله أكثر قدرة على التعميم، و توضح النتائج في الجدولين (6.4) و (7.4) أن النموذج أعطى نسب دقة مرتفعة مقارنة بنسب الدقة المتحصل عليها من تجارب الجزء الثاني، و كذلك بالنسبة للانحياز توضح نتائج الدقة لكلا الفئتين أن التفاوت أصبح أقل بشكل كبير مقارنة بجميع النتائج السابقة، و من خلال هذه النتائج فإنه يمكننا أن نستنتج أن الطرق المقترحة أدت إلى تحسين النموذج و جعله أكثر كفاءة في إعطاء النتائج.

أثبتت النتائج أيضا أنه عند استخدام طريقة الدمج بين Data Augmentation و Oversampling أعطت نتائج أعلى في جميع المقاييس مقارنة بالطريقة التي تم فيها الدمج بين Data Augmentation و Undersampling، و لهاذا سيتم اعتمادها و تطبيقها في تجارب الأجزاء القادمة.

4.4 التجربة الرابعة

من خلال النتائج التي تم التوصل إليها في الجزء الثالث و التي من خلالها تم إثبات تفوق الطريقة الثانية و التي تم فيها بالدمج بين Data Augmentation و Oversampling، نلاحظ وجود تذبذب وتباين كبير في معدل الخطأ الذي أنتجه النموذج بالنسبة لمجموعة الاختبار في كل مجموعة من مجموعات البيانات حيث من المفترض أنه يقل كلما قل معدل الخطأ في مجموعة التدريب.

تتعلم الشبكات العصبية مجموعة من الأوزان التي تحدد أفضل مدخلات للمخرجات، و كلما زادت مدة تدريب الشبكة كلما أصبحت الأوزان أكثر تخصصا لبيانات التدريب و بالتالي ستتضاعف الأوزان في الحجم من أجل التعامل مع تفاصيل الأمثلة التي تظهر في بيانات التدريب، يمكن أن تكون الشبكة ذات الأوزان الكبيرة علامة على وجود شبكة غير مستقرة حيث يمكن أن تؤدي التغييرات الصغيرة في المدخلات إلى تغييرات كبيرة في المخرجات، فتتجاهل الشبكة الأوزان الصغيرة و التي قد تكون مهمة و تأثر على عملية التدريب، تعتبر هذه علامة توضح سبب تناقص معدلات خطا للنموذج أثناء

تدريبه و ارتفاعها عند اختباره على البيانات الجديدة المتمثلة في مجموعة الاختبار، حل هذه المشكلة يتطلب تحديث النموذج المستخدم و إعادة ضبطه ليتعلم على إبقاء الأوزان صغيرة و عدم تجاهلها، و هذا ما يسمى بالتحديد بتنظيم الأوزان Weights Regularization، حيث تم تغيير عملية حساب الخسارة المستخدمة في تحديد قيم الأوزان لتحسين الشبكة و ذلك من خلال تطبيق تقنية (L2 Regularization)، و التي يتم تمثيلها من خلال المعادلة التالية:

$$Loss = -\sum_{i=1}^{output\ size} y_i . log\ \hat{y_i} + \sum_{i=1}^{n} w^2$$

يتم حساب مجموع مربعات الأوزان w^2 وإضافتها إلى دالة الخسارة المستخدمة، و بالتالي كلما كانت الأوزان كبيرة ستكون العقوبة أكبر و بالتالي ستكون درجة الخسارة أكبر.

1.4.4 التدريب باستخدام تنظيم الأوزان Weights Regularization

النتائج المتحصل عليها بعد تطبيق Weights Regularization كانت كالتالي:

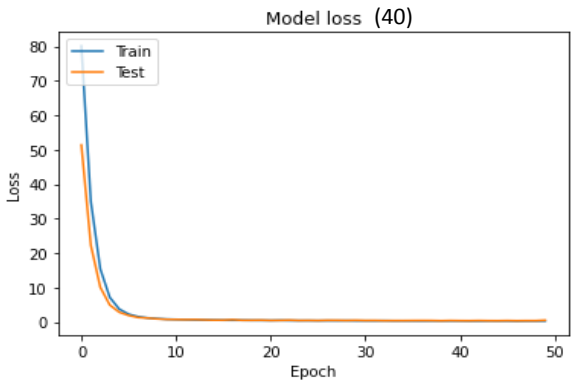

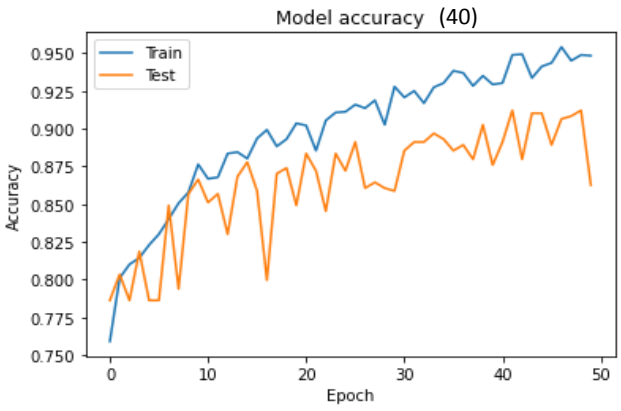

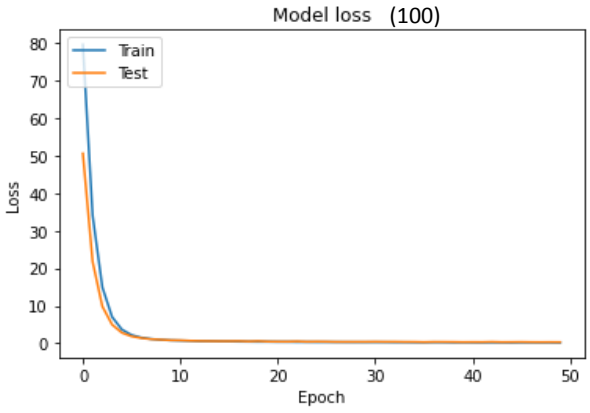

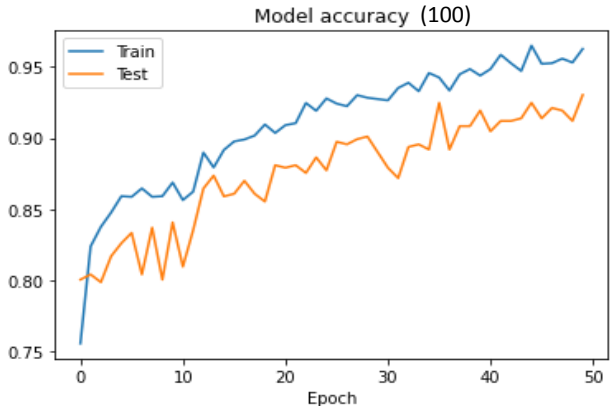

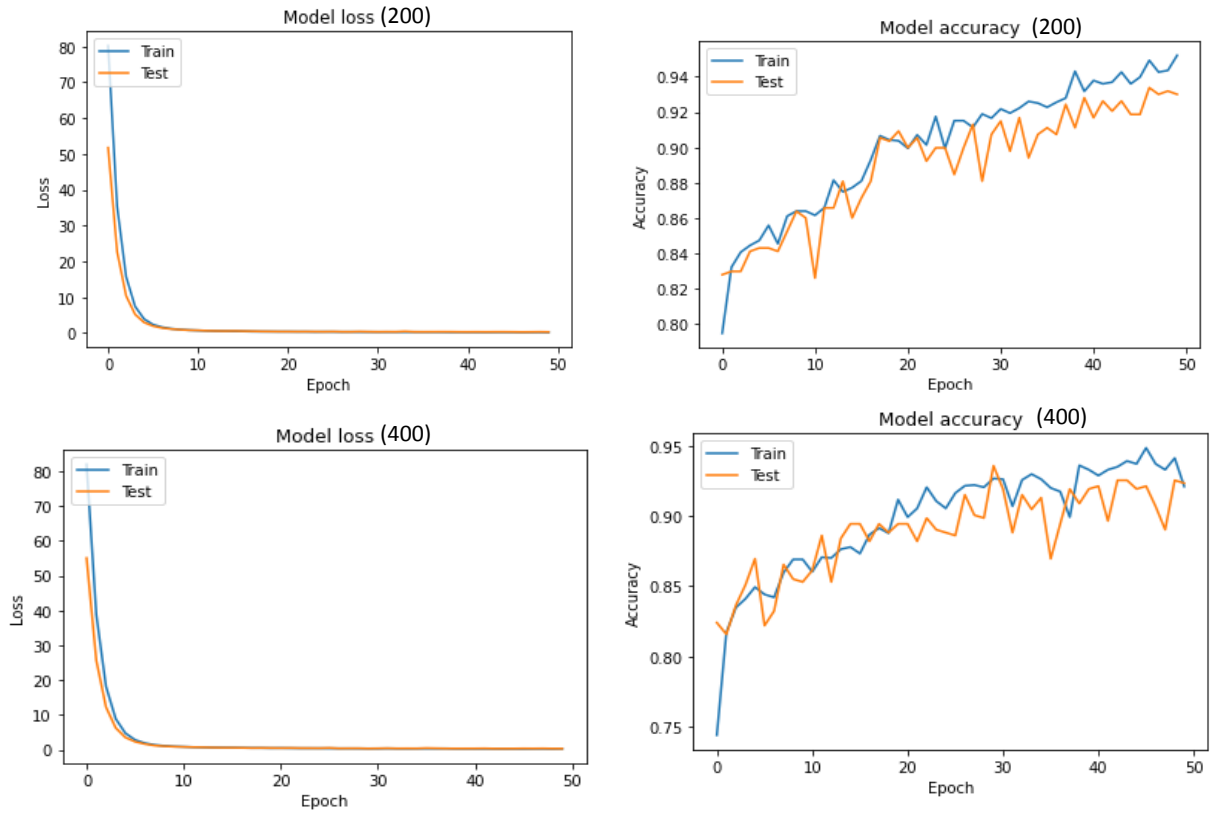

شكل (13.4) يوضح نسبة الدقة ومعدل الخطأ لكل مجموعة بيانات بعد تطبيق Weights Regularization

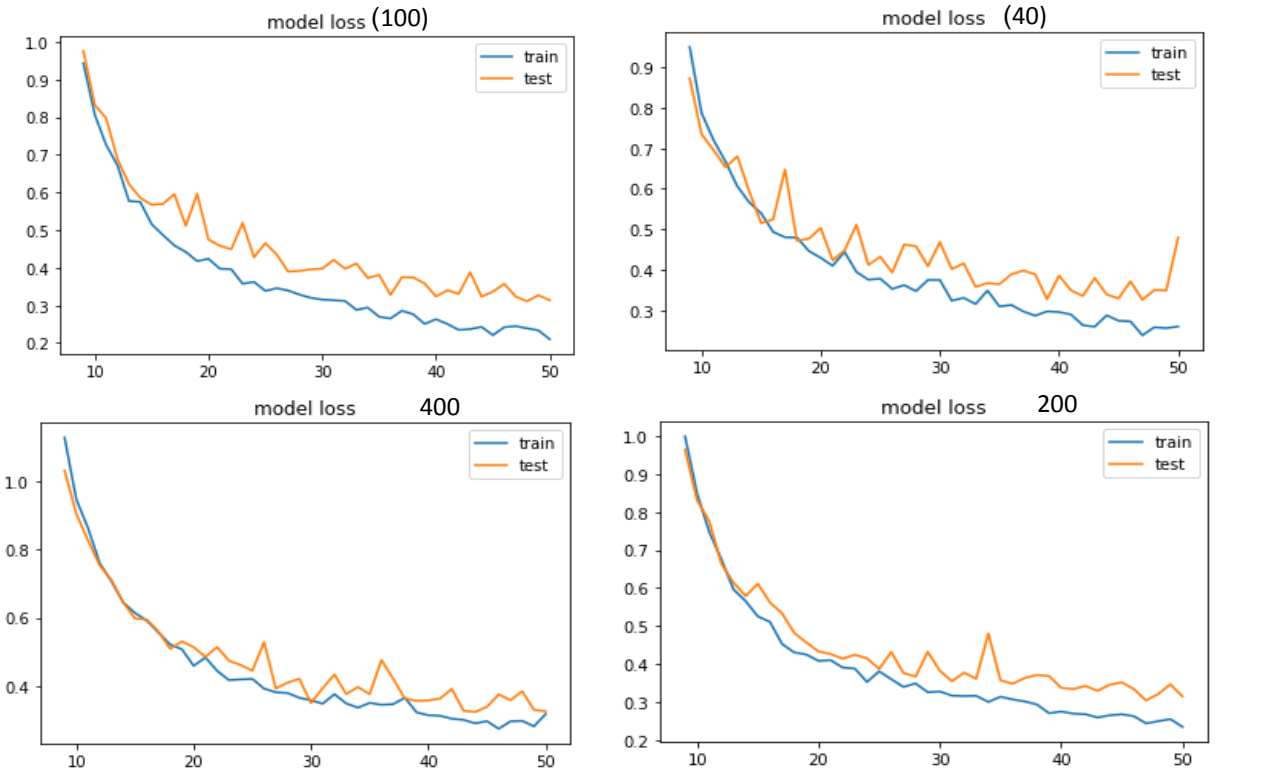

شكل (14.4) يوضح نسبة الخطأ لكل مجموعة بيانات من Epoch 9 بعد تطبيق Weights Regularization

conf_matrix data(100)

	Benign	Malignant
Benign	249	9
Malignant	35	253

conf_matrix data(40)

	Benign	Malignant
Benign	240	10
Malignant	23	251

conf_matrix data(400)

	Benign	Malignant
Benign	231	5
Malignant	34	213

conf_matrix data(200)

	Benign	Malignant
Benign	239	11
Malignant	23	256

شكل (15.4) يوضح نتائج مصفوفة الارتباك لكل مجموعة بيانات بعد تطبيق Weights Regularization

جدول (8.4) يوضح نتائج أداء النموذج بعد تطبيق Weights Regularization

Precision	Recall	F1-score	Support	Class	Accuracy	Size	Data
96%	91%	94%	250	**Benign**	94%	524	**40**×
92%	96%	94%	274	**Malignant**			
97%	88%	92%	258	**Benign**	92%	546	**100**×
88%	97 %	92%	288	**Malignant**			
96%	91%	93%	250	**Benign**	94%	529	**200**×
92%	96%	94%	279	**Malignant**			
98%	87%	92%	236	**Benign**	92%	483	**400**×
86%	98%	92%	247	**Malignant**			

توضح المنحنيات التي على اليسار في الشكل (13.4) معدل الخطأ بعد تطبيق تنظيم الأوزان، حيث تشير إلى أن نسبة معدل الخطأ للنموذج مرتفعة عند تدريب النموذج في البداية و تنخفض النسب تدريجيا بعد كل Epoch، و بسبب التباين في الخطأ بعد تطبيق تنظيم الاوزان لا تظهر نسبة الخطأ بعد Epoch رقم 9 و ذلك لأن النسب أصبحت أصغر و أقل تباين من قبل لذلك تمت إعادة رسمها ابتداء من Epoch رقم 9 كما هو موضح في الشكل (14.4)، يوضح الشكل أنه رغم ارتفاع معدل الخطأ لمجوعة التدريب مقارنة بالنتائج السابقة في الشكل (11.4) إلا أن التفاوت في نسب الخطأ بين مجموعة التدريب والاختبار أصبح أقل حيث أصبحت نسبة الخطأ لمجموعة التدريب منخفضة مقارنة بالنتائج في التجارب السابقة و هذه النتائج توضح مدى تأثير تنظيم الأوزان في التقليل من معدلات الخطأ و تحسين أداء النموذج.

و من خلال المقارنة بين النتائج التي تم الحصول عليها من التجربة الأخيرة في الجزء الثالث و المتمثلة في الجدول (7.4) و نتائج الجدول (8.4) التي تحصلنا عليها من هذه التجربة، نلاحظ أن قيم Precision التي توضح عدد الصور التي صنفها النموذج بطريقة صحيحة بالنسبة لكل فئة، أن القيم في الفئة الإيجابية أصبحت أعلى من القيم في الفئة السلبية بعد تطبيق تنظيم الأوزان على عكس النتائج السابقة التي كانت فيها القيم السلبية أعلى، و توضح قيم Recall التي تشير إلى عدد الصور في الفئة التي صنفها النموذج بطريقة صحيحة نسبة إلى عدد الصور التي صنفها النموذج أنها تنتمي لهذه الفئة أنه عند تطبيق تنظيم الأوزان أصبحت القيم الفئة الايجابية أقل من الفئة السلبية على عكس النتائج السابقة التي كانت فيها قيم الفئة الإيجابية أعلى، ونستنتج من ذلك أنه عند تطبيق تنظيم الأوزان أصبح النموذج يعطي نتائج أفضل بالنسبة للفئة الإيجابية نسبة لجميع مجموعات البيانات.

5.4 التجربة الخامسة

في هذا الجزء تم زيادة عدد مرات تدريب النموذج Epoch و ذلك بالاعتماد على النتائج التي تم الحصول عليها في الجزء الرابع و التي أثبتت تحسن أداء النموذج بعد تطبيق Data Augmentation و Oversampling و Weight Regularization، تم في التجارب السابقة تدريب النموذج على Epoch 50، في هذا الجزء سندرب النموذج على Epoch 100 و ذلك خطوة نهائية في التدريب و تقييم مدى تأثير عدد مرات التدريب على أداء النموذج.

1.5.4 التدريب بعد زيادة عدد Epoch

النتائج المتحصل عليها بعد زيادة عدد مرات تدريب النموذج إلى 100 كانت كالتالي:

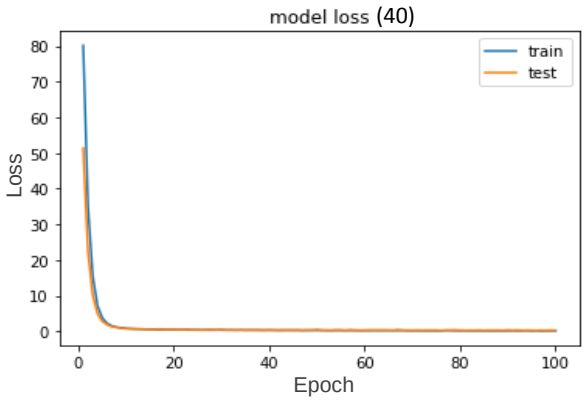

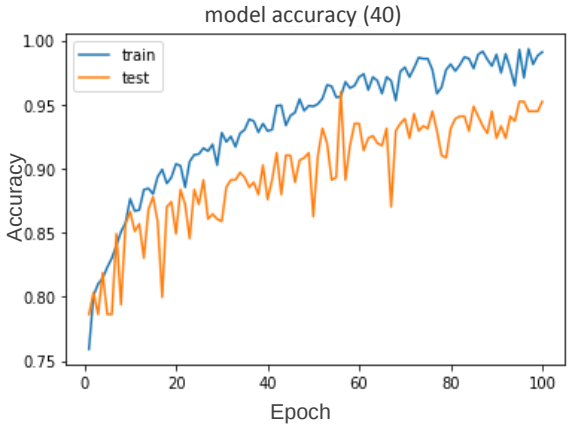

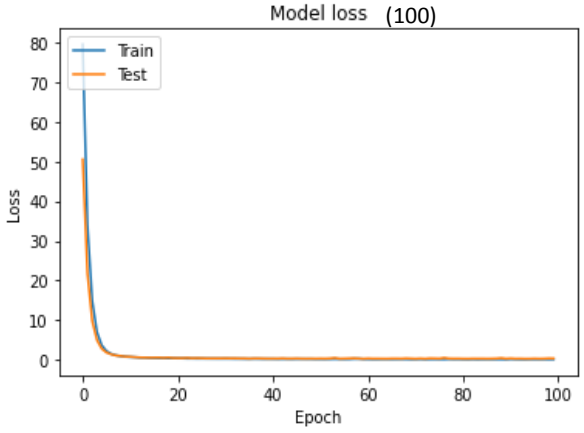

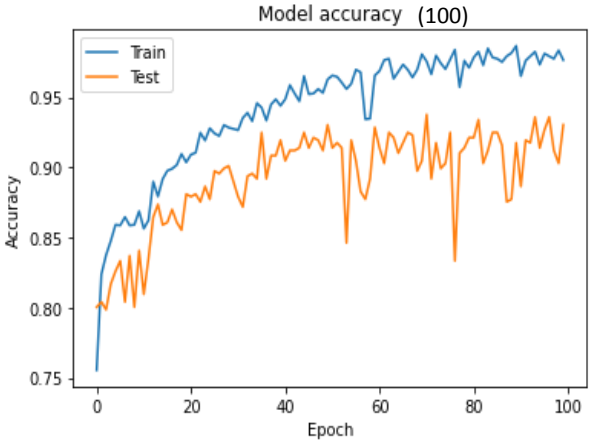

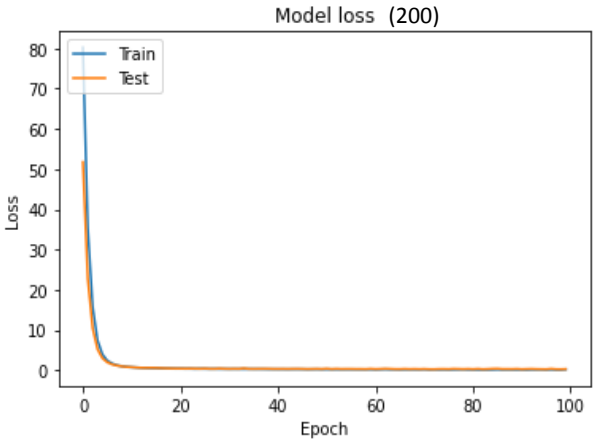

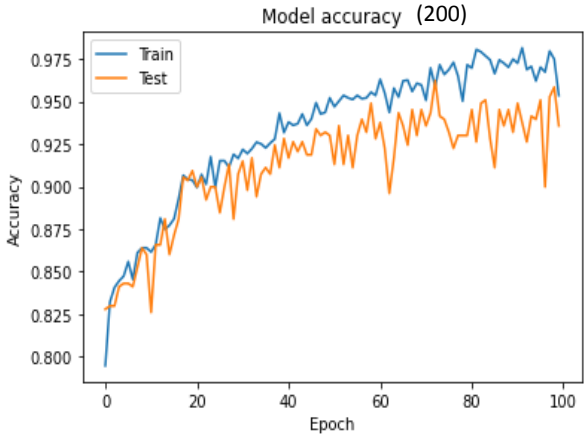

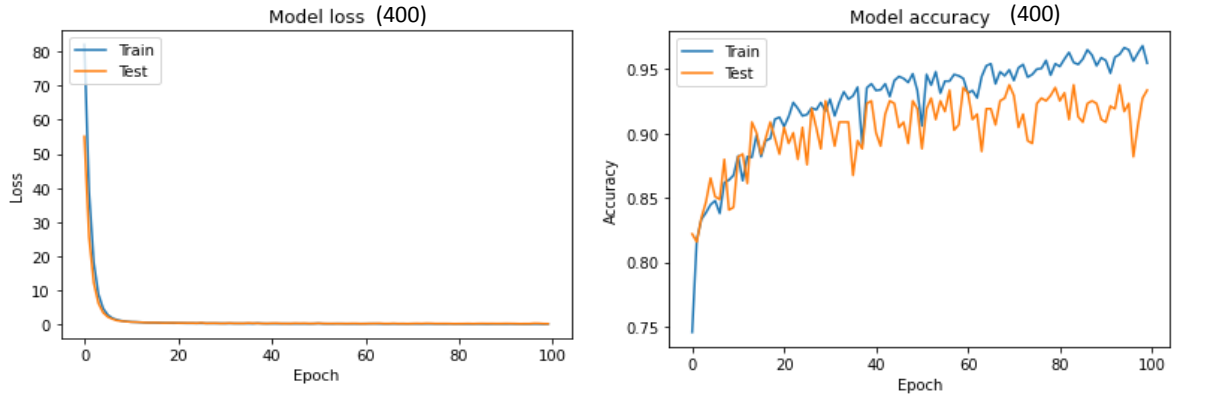

شكل (16.4) يوضح نسبة الدقة ومعدل الخطأ لكل مجموعة بيانات بعد زيادة عدد Epoch

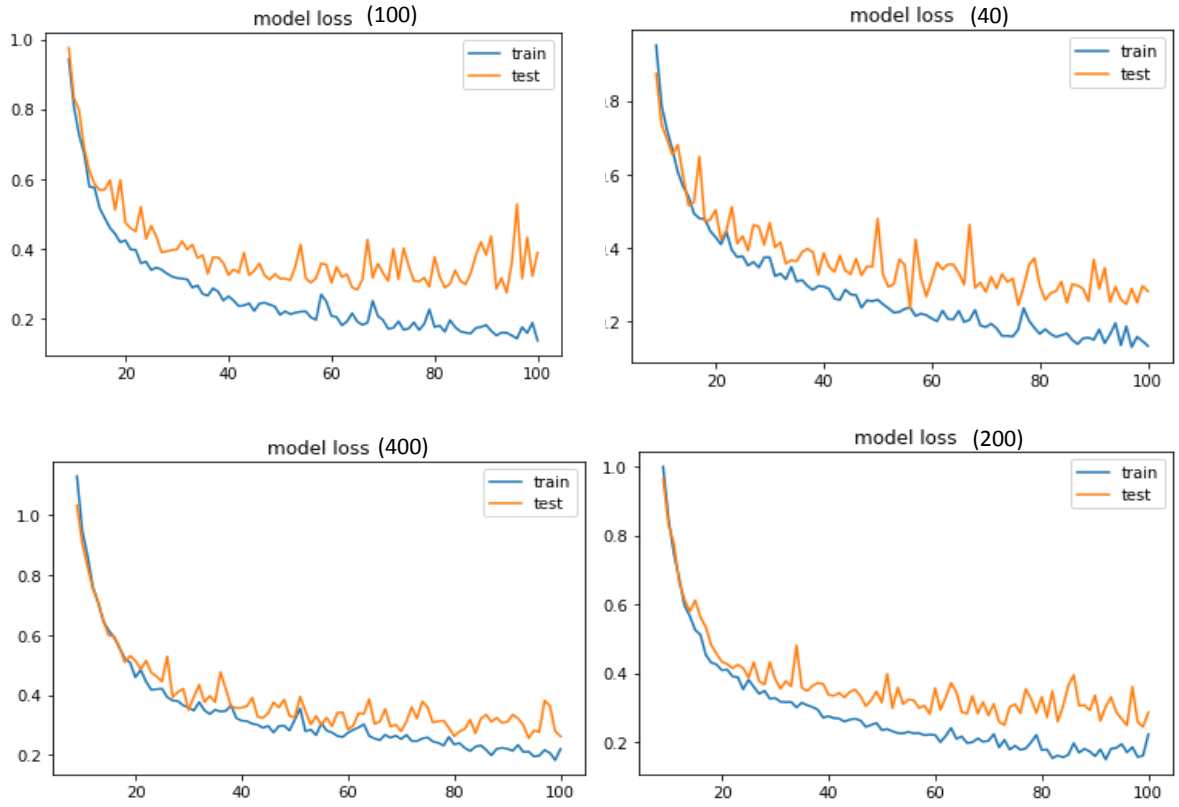

شكل (17.4) يوضح نسبة الدقة ومعدل الخطأ لكل مجموعة بيانات من Epoch 9 بعد زيادة عدد Epoch

conf_matrix data(100)

	Benign	Malignant
Benign	252	6
Malignant	26	262

conf_matrix data(40)

	Benign	Malignant
Benign	233	17
Malignant	15	259

conf_matrix data(200)

	Benign	Malignant
Benign	222	14
Malignant	16	231

conf_matrix data(400)

	Benign	Malignant
Benign	236	14
Malignant	22	257

شكل(18.4) يوضح نتائج مصفوفة الارتباك لكل مجموعة بيانات بعد زيادة عدد

جدول (9.4) يوضح نتائج أداء النموذج بعد زيادة عدد epoch

Precision	**Recall**	**F1-score**	**Support**	**Class**	**Accuracy**	**Size**	**Data**
93%	94%	94%	250	**Benign**	94%	524	**40×**
95%	94 %	94%	274	**Malignant**			
98%	91%	94%	258	**Benign**	94%	546	**100×**
91%	98%	94%	288	**Malignant**			
94%	91%	93%	250	**Benign**	93%	529	**200×**
92%	95%	93%	279	**Malignant**			
94%	93%	94%	236	**Benign**	94%	483	**400×**
94%	94%	94%	247	**Malignant**			

توضح المنحنيات في الشكل (16.4) ارتفاع نسبة دقة النموذج أثناء التدريب مقارنة بالنتائج السابقة و تشير النتائج في الشكل (17.4) إلى انخفاض نسبة الخطأ كذلك، أما بالنسبة للنتائج في الجدول (9.4) توضح أن نسبة الدقة ارتفعت بالنسبة لمجموعة البيانات (×100) و (×400) حيث كانت نسبة الدقة 92% فأصبحت 94% أما بالنسبة لمجموعة البيانات (×40) فإن الدقة تساوي 94% أي لا يوجد تتغير في النتيجة ، و في مجموعة البيانات (×200) قلت نسبة الدقة بمقدار واحد حيث كانت 94% فأصبحت 93% ، و تساوت نسب للفئات في المقياس F1-score مع نسبة دقة النموذج و هذا يعني أن نسبة الدقة التي توصل إليها النموذج تعكس حقيقية أداء النموذج بشكل عام بالنسبة للجميع الفئات، و من خلال هذه النتائج نستنتج مدى تأثير عدد مرات التدريب على دقة النموذج و مدى تحسن أدائه بعدما تمت بزيادتها، أي أنه كلما زاد عدد مرات تدريب النموذج زاد أداءه وأعطى نتائج أفضل.

الفصل الخامس

الخلاصة

5. الخلاصة

تم في هذا البحث تصنيف صور سرطان الثدي باستخدام نموذج من نماذج الشبكات العصبية الالتفافية، حيث تم تدريب نموذج Alexnet على تصنيف صور الأنسجة Histology Image لسرطان الثدي المأخوذة من مجموعة بيانات Breakhis، والتي تمت إعادة ترتيبها لتدريب النموذج على التصنيف الثنائي، تم تدريب النموذج من خلال مجموعة من التجارب التي أجريت لدراسة العوامل التي تؤثر على قدرة النموذج ودراسة تأثير تقنيات التحسين المستخدمة على هذه العوامل ومدى قدرتها في تحسين النموذج، أظهرت النتائج الأولية انحياز النموذج للفئة السلبية و ذلك بسبب عدم توازن الفئتين تبين أيضا أن النموذج يعاني من مشكلة فرط تخصيص Overfitting وذلك بسبب قلة بيانات التدريب، تم استخدام الزيادة الافتراضية للبيانات Data Augmentation لحل مشكلة فرط التخصيص و أجريت مقارنة بين Undersampling و Oversampling للموازنة بين الفئتين، كل طريقة حلت المشكلة المستخدمة لأجلها فقط تم الدمج بينها لحل جميع المشاكل، اثبتت طريقة الدمج بين Oversampling و Data Augmentation تفوقها في إعطاء النتائج ، ولوضع حد للأوزان ذات القيم الكبيرة و التي أدت إلى ارتفاع معدلات الخطأ عند اختبار النموذج تم استخدام تنظيم الأوزان Weight Regularization، في الجزء الأخير تم زيادة عدد مرات تدريب النموذج إلى Epoch 100 و ذلك لتحسين قدرة النموذج، توضح النتائج النهائية انخفاض معدلات الخطأ في كل مجموعات البيانات و ارتفاع نسب الدقة للنموذج، النتائج التي تم الحصول عليها بعد التجربة الأخيرة كانت كالتالي: حقق النموذج نسبة دقة تصل إلى 94% لمجموعة البيانات (×40) و (×100) و (×400)، و 93% في مجموعة البيانات (×200).

1.5 الخبرات المكتسبة

توجد العديد من الخبرات التي تم اكتسابها في هذا البحث منها:

1. تعلم لغة برمجة جديدة و هي لغة Python.
2. اكتساب الخبرة في مجال التعلم العميق بشكل عام و في التعامل مع التقنيات والأدوات المستخدمة في بناء الشبكات العصبية الالتفافية على وجه الخصوص.
3. تعلم طرق و أساليب الكتابة بالطريقة العلمية.

2.5 الصعوبات والعراقيل

لا شك أن أي عمل يواجه العديد من الصعوبات والعراقيل ولعل أبرز الصعوبات التي واجهة هذا البحث هي:

1. قلة الدراسات و المراجع العلمية باللغة العربية التي لها صلة بموضوع البحث.
2. محدودية الموارد المستخدمة في عملية تدريب النموذج والتي تحتاج متطلبات تشغيل عالية.
3. الوقت الطويل الذي تستغرقه كل عملية تدريب.

3.5 التوصيات والأفاق المستقبلية

1. تدريب النموذج على التصنيف المتعدد و مقارنة أداءه في التصنيف الثنائي.
2. استخدام أكثر من نموذج للتعلم العميق في التصنيف صور سرطان الثدي المستخدمة ومقارنتها.
3. تدريب النموذج المستخدم على تصنيف صور لأمراض مختلفة.
4. تحويل النموذج إلى تطبيق يعمل على الهاتف دون الحاجة إلى الاتصال بالإنترنت.

المراجع

المراجع العربية

1- ميلاد وزان، د. علاء طعيمة، "التعلم العميق: من الأساسيات حتى بناء شبكة عصبية عميقة بلغة البايثون"، كلية علوم الحاسوب وتكنولوجيا المعلومات، جامعة القادسية، العراق، 2022م.

2- قصي حبيب الحسيني، أحمد عبد الأمير الساعدي، "مقدمة في الشبكات العصبية الاصطناعية"، جامعة الإمام جعفر الصادق عليه السلام، كركوك، العراق، 2006م.

3- د. ظافر رمضان مطر، رهاد عماد صليوا، "مقارنة أداء التنبؤ بين بعض الشبكات العصبية الاصطناعية ومنهجية (بوكس – جنكز) مع التطبيق"، المجلة العراقية للعلوم الإحصائية، ص ص [51–76] ، (28) 2019.

4- سعدة فرج السنوسي فرج، فاطمة عبد الله عبد الرحيم، أ.أبوبكر هامل، "دراسة احتمالية وجود علاقة بين مستضل البروستاتا ومريضات سرطان الثدي المترددات على مركز الاورام سبها"، كلية العلوم جامعة سبها، ليبيا، 2017.

المراجع الإنجليزية

5 Kundale, Jyoti, and Sudhir Dhage. "Classification of breast cancer using histology images: Handcrafted and pre-trained features based approach." *IOP Conference Series: Materials Science and Engineering*. Vol. 1074. No. 1. IOP Publishing, 2021.
.

6- Elsanosi, Aden Hassan Mergani. *Detecting Pulmonary Tuberculosis in Chest X-Ray Images Using Convolutional Neural Network*. Diss. Sudan University of Science and Technology, 2021.

7- Dradi, Wafa Hadi. *Brain Tumor Classification by Using Gray Scaled Deep Neural Network*. Diss. Alzawia University, 2021.

8- Sharma, Shallu, Rajesh Mehra, and Sumit Kumar. "Optimised CNN in conjunction with efficient pooling strategy for the multi-classification of breast cancer." *IET Image Processing* 15.4 (2021): 936-946.

9- Spanhol, F. A., Oliveira, L. S., Petitjean, C., and Heutte, L. l. "A dataset for breast cancer histopathological image classification." *Ieee transactions on biomedical engineering* 63.7 (2015): 1455-1462.

10- Albawi, Saad, Tareq Abed Mohammed, and Saad Al-Zawi. "Understanding of a convolutional neural network." *2017 international conference on engineering and technology (ICET)*. Ieee, 2017.

11- Krizhevsky, Alex, Ilya Sutskever, and Geoffrey E. Hinton. "Imagenet classification with deep convolutional neural networks." *Advances in neural information processing systems* 25 (2012).

12- Spanhol, F. A., Oliveira, L. S., Petitjean, C., and Heutte, L. "Breast cancer histopathological image classification using convolutional neural networks," *international joint conference on neural networks (IJCNN)*. IEEE, 2016.

13- Karthiga, R., and K. Narashimhan. "Deep convolutional neural network for computer-aided detection of breast cancer using histopathology images." *Journal of Physics: Conference Series*. Vol. 1767. No. 1. IOP Publishing, 2021.

14- Bardou, Dalal, Kun Zhang, and Sayed Mohammad Ahmad. "Classification of breast cancer based on histology images using convolutional neural networks." *Ieee Access* 6 (2018): 24680-24693.

15- Ahmad, Hafiz Mughees, Sajid Ghuffar, and Khurram Khurshid. "Classification of breast cancer histology images using transfer learning." *2019 16th International Bhurban .conference on applied sciences and technology (IBCAST)*. IEEE, 2019.

16- Senan, E. M., Alsaade, F. W., Al-Mashhadani, M. I. A., Theyazn, H. H., and Al-Adhaileh, M. H. "Classification of histopathological images for early detection of breast cancer using deep learning." *Journal of Applied Science and Engineering* 24.3 (2021): 323-329.

17- Al Rahhal, Mohamad Mahmoud. "Breast cancer classification in histopathological images using convolutional neural network." *international journal of advanced computer science and applications* 9.3 (2018).

18- Lévy, Daniel, and Arzav Jain. "Breast mass classification from mammograms using .deep convolutional neural networks." *arXiv preprint arXiv:1612.00542* (2016).

19- Yu, S., Liu, L., Wang, Z., Dai, G., and Xie, Y. "Transferring deep neural networks for the differentiation of mammographic breast lesions." *Science China Technological .Sciences* 62.3 (2019): 441-447.

20- Mechria, Hana, Mohamed Salah Gouider, and Khaled Hassine. "Breast Cancer .Detection using Deep Convolutional Neural Network." *ICAART (2)*. 2019.

21Ragab, D. A., Sharkas, M., Marshall, S., and Ren, J. "Breast cancer detection using deep convolutional neural networks and support vector machines." *PeerJ* 7 (2019): e6201.

المواقع الالكترونية

22- https://www.webteb.com/articles/25615_الفرق-بين-الورم-الحميد-والخبيث،2022/8/21ص ،2:30.

23- https://www.moh.gov.sa/HealthAwareness/EducationalContent/wh/BreastCancer/Pages/default.aspx, 2022/8/21,
ص2:30.

24- https://www.alrab7on.com/artificial-neural-networks/،2022/8/21ص ،3:45.

25- https://colab.research.google.com/،2022/8/19م ،4:30.

26- https://www.kaggle.com/،2022/8/21م ،6:11.