

نظام محسن لتصنيف شدة اعتلال الشبكية لمرضى السكري باستخدام شبكة Xception عن طريق معالجة صور X-RAY

أ. ابوبكر الصديق بن شتوان - م. زياد معاذ الفقيه

قسم هندسة البرمجيات - كلية تكنولوجيا المعلومات - جامعة السلام الدولية

الملخص:

يهدف هذا البحث إلى تطوير نظام ذكي لتصنيف شدة اعتلال الشبكية السكري (Diabetic Retinopathy) باستخدام تقنيات التعلم العميق. يعتمد النظام المقترح على معمارية Xception المحسنة مع تطبيق تقنيات متقدمة لتخفيف مشكلة فرط التعلم (Overfitting) ومعالجة عدم توازن الفئات. تم استخدام مجموعة بيانات APTOS 2019 التي تحتوي على 3,662 صورة لشبكية العين، مصنفة إلى خمس فئات تمثل درجات مختلفة من شدة المرض. شملت المنهجية تحضير البيانات باستخدام تقنيات تحسين متقدمة، وبناء نموذج هجين يجمع بين مزايا النقل التعليمي (Transfer Learning) وطبقات Dropout متكيفة، مع تطبيق دالة خسارة موزونة لمعالجة عدم توازن الفئات. حقق النموذج المقترح دقة تحقق (Validation Accuracy) بلغت 95.20% ومعدل خسارة تحقق 0.1749، مما يدل على قدرته العالية على التعميم والتنبؤ بالحالات غير المرئية سابقاً. أظهر التحليل المقارن أن النموذج يتفوق على العديد من الدراسات السابقة في معالجة مشكلة عدم توازن الفئات في مهام التصنيف الطبي متعدد الفئات. تؤكد هذه النتائج إمكانية استخدام النموذج المقترح كأداة مساعدة فعالة للأطباء في التشخيص المبكر والدقيق لاعتلال الشبكية السكري، خاصة في المناطق التي تعاني من نقص الكوادر الطبية المتخصصة.

الكلمات المفتاحية: التعلم العميق، الشبكات العصبية الالتفافية، اعتلال الشبكية السكري، Xception، عدم توازن الفئات، التشخيص الطبي الآلي.

1. مقدمة :

في العقود الأخيرة، شهد مجال التعلم الآلي، وخاصة التعلم العميق، تطوراً هائلاً في تطبيقات التشخيص الطبي. يُعد اعتلال الشبكية السكري (Diabetic Retinopathy) أحد المضاعفات الخطيرة لمرض السكري

التي قد تؤدي إلى العمى إذا لم يتم اكتشافها وعلاجها في مراحلها المبكرة. وفقاً لمنظمة الصحة العالمية، يعاني أكثر من 425 مليون شخص من مرض السكري عالمياً، وحوالي ثلثهم يعانون من أشكال مختلفة من اعتلال الشبكية السكري [1]. يعتمد التشخيص التقليدي لهذا المرض على فحص الصور السريرية لشبكية العين من قبل أطباء العيون المتخصصين، وهي عملية تستغرق وقتاً طويلاً وتعتمد على الخبرة السريرية، مما يجعلها عرضة للأخطاء البشرية خاصة في المناطق التي تعاني من نقص الكوادر الطبية.

أظهرت تقنيات التعلم العميق، وخاصة الشبكات العصبية الالتفافية (CNN)، نجاحاً ملحوظاً في تحليل الصور الطبية وتصنيف الأمراض. ومع ذلك، تواجه التطبيقات العملية في هذا المجال تحديات متعددة، أبرزها مشكلة عدم توازن الفئات (Class Imbalance) التي تظهر عندما تكون بعض فئات المرض أقل تمثيلاً من غيرها في مجموعة البيانات. في حالة اعتلال الشبكية السكري، تكون الفئات المتقدمة من المرض (مثل الدرجة 4) أقل شيوعاً من الفئات المبكرة، مما يؤدي إلى تحيز النموذج نحو الفئات الأكثر تمثيلاً.

تهدف هذه الدراسة إلى تطوير نظام محسن لتصنيف شدة اعتلال الشبكية السكري يعالج تحدي عدم توازن الفئات عبر دمج تقنيات متعددة لتحسين الأداء على جميع الفئات. تكمن المساهمة الرئيسية لهذا البحث في:

1. تطوير هيكلية محسنة لشبكة Xception مع طبقات Dropout متكيفة لتحسين أداء النموذج على

الفئات الأقل تمثيلاً

2. تطبيق دالة خسارة موزونة مخصصة لمعالجة مشكلة عدم توازن الفئات

3. تقديم تحليل تفصيلي لأداء النموذج عبر مقاييس متعددة تتجاوز الدقة التقليدية

4. مقارنة الأداء مع الدراسات السابقة باستخدام نفس مجموعة البيانات لضمان المقارنة العادلة

2. مشكلة البحث

تواجه أنظمة التشخيص التلقائي لاعتلال الشبكية السكري (Diabetic Retinopathy) تحديات تقنية جوهرية تتعلق بشكل أساسي بمشكلة عدم توازن الفئات (Class Imbalance) في مجموعات البيانات الطبية، إلى جانب التعقيدات المرتبطة بتصنيف الصور الطبية متعددة الفئات. في سياق مجموعات البيانات القياسية مثل APTOS 2019، يظهر توزيع غير متجانس بشكل كبير بين الفئات الخمس لشدة المرض، حيث تمثل الفئة 0 (العين السليمة) ما يقارب 49.3% من إجمالي البيانات، بينما تمثل الفئة 3 (الاعتلال الشديد) فقط 5.3% من العينات. هذا التوزيع غير المتوازن يؤدي إلى تحيز النماذج التدريبية نحو الفئات الأكثر تمثيلاً، مما يقلل من فعالية النموذج في التعرف على الحالات الحرجة (مثل الدرجة 3 والدرجة 4) التي تتطلب تدخلاً طبياً عاجلاً.

الفجوة البحثية الرئيسية التي يسهم هذا البحث في سدها تتمثل في تطوير هيكلية محسنة لنموذج Xception مع تطبيق تقنيات متقدمة لمعالجة عدم توازن الفئات، دون الاعتماد على الطرق التقليدية البسيطة مثل إعادة العينات (Resampling). يهدف البحث إلى تقديم حل يجمع بين تحسين البيانات (Data Augmentation) المخصص للصور الطبية، ودالة خسارة موزونة (Weighted Loss Function)، وطبقات Dropout متكيفة، لتحقيق أداء متوازن عبر جميع الفئات الخمس لشدة اعتلال الشبكية السكري، مع الحفاظ على قدرة النموذج على التعميم (Generalization) ومنع فرط التعلم.

3. الدراسات السابقة

أجرى Alyoubi و Shalash (2020) مراجعة شاملة لأساليب الكشف عن اعتلال الشبكية السكري باستخدام تقنيات التعلم العميق. ركزت دراستهم على تحليل قواعد البيانات الشائعة المستخدمة في هذا المجال، مثل Kaggle (80,000 صورة)، DRIVE، HRF، Messidor-2 (1,748 صورة)، و EyePACS-1 (9,963 صورة). أشارت نتائجهم إلى أن استخدام الشبكات العصبية الالتفافية (CNN) يوفر نتائج أكثر دقة وكفاءة مقارنة بالطرق اليدوية التقليدية. كما قدمت الدراسة مقارنة لأداء هذه القواعد، حيث بلغت دقة Kaggle 75% مع حساسية 30% وخصوصية 95%، بينما

حققت DRIVE دقة 98.30% وحساسية 95.82% وخصوصية 79.96%. وحققت Messidor-2 حساسية 96.8% وخصوصية 87.0%، وحققت EyePACS-1 دقة 97.5% وحساسية 93.4% وخصوصية 93.4%.

اقترح Harry وآخرون (2016) نظامًا يعتمد على شبكة عصبية التلافيفية مخصصة لتصنيف صور الشبكية إلى خمس مراحل من اعتلال الشبكية السكري باستخدام مجموعة بيانات Kaggle. تضمنت المنهجية تطبيع الألوان وتغيير حجم الصور إلى 512×512 بكسل. تتكون البنية المقترحة من 10 طبقات تلافيفية، و 8 طبقات تجميع أعظمي، و 3 طبقات كثيفة الاتصال. حقق النظام دقة 75% وخصوصية 95%، لكن مع حساسية منخفضة نسبيًا (30%)، مما يشير إلى صعوبة اكتشاف الحالات المبكرة للمرض.

استخدم Mobeen وآخرون (2019) مجموعة بيانات MESSIDOR المكونة من 1,200 صورة مصنفة إلى أربع مراحل من اعتلال الشبكية السكري. قام الباحثون بمقارنة أداء شبكة عصبية مخصصة مع نماذج مسبقة التدريب (AlexNet)، VGG-16، و SqueezeNet. شملت مرحلة المعالجة المسبقة قص الصور وتغيير حجمها إلى 244×244 بكسل وتحسينها باستخدام مساواة المدرج التكراري. تتألف الشبكة المخصصة من طبقتين تلافيفيتين، وطبقتين تجميع أعظمي، وثلاث طبقات كثيفة الاتصال. حققت الشبكة المخصصة أفضل النتائج بدقة 98.15% وخصوصية 97.87% وحساسية 98.94%. ومع ذلك، فإن الدراسة اقتصرت على أربع فئات فقط، واعتمدت على مجموعة بيانات صغيرة نسبيًا.

اقترح Zhang وآخرون (2019) نظامًا متكاملًا للكشف عن اعتلال الشبكية السكري باستخدام مجموعة بيانات خاصة تحتوي على 13,767 صورة موزعة إلى أربع فئات. تضمنت المنهجية قص الصور وتغيير حجمها، وتحسينها باستخدام مساواة المدرج التكراري ومساواة المدرج التكراري التكيفية، وتوسيع البيانات، وتحسين التباين للصور الداكنة. استخدم الباحثون عدة معماريات CNN مسبقة التدريب (ResNet50)، InceptionV3، InceptionResNetV2، Xception،

و(DenseNets، مع إضافة طبقات كثيفة الاتصال وعملية إعادة تدريب جزئي (Fine-tuning). حقق النظام المدمج دقة 96.5% وخصوصية 98.9% وحساسية 98.1%. ومع ذلك، لم يتم استخدام مجموعة بيانات قياسية، مما يجعل المقارنة مع دراسات أخرى صعبة.

استخدم Li وآخرون (2020) شبكة ResNet50 مع وحدات انتباه (Attention Modules) لتصنيف مجموعة Messidor إلى صور قابلة للإحالة أو غير قابلة، وتصنيف مجموعة IDRiD إلى خمس مراحل من اعتلال الشبكية السكري وثلاث مراحل من الوذمة الصفراء السكري (DME). استخدمت الميزات المستخرجة من ResNet50 كمداخلات لوحدين تحتويان على طبقات تجميع (متوسط وأعظمي)، وطبقات ضرب، ودمج، وطبقات تلافيفية وكثيفة الاتصال. حققت النتائج حساسية 92%، وAUC 96.3%، ودقة 92.6% لمجموعة Messidor، بينما كانت الدقة لمجموعة IDRiD 65.1% ومع ذلك، لم تتضمن الدراسة كشف الآفات في الصور بشكل مباشر.

استخدم Wu وآخرون (2020) شبكة CNN مخصصة لاستخراج الأوعية الدموية في شبكية العين من مجموعات البيانات العامة DRIVE، STARE، وCHASE. شملت المنهجية تحويل الصور من صيغة RGB إلى الرمادية، وتطبيعها وتحسينها باستخدام تقنية CLAHE، واستخراج مقاطع (patches) بحجم 48×48 بكسل، وتوسيع البيانات. تتكون الشبكة من هيكل ترميز-فك ترميز مع اتصالات تخطي، وتتضمن طبقات تلافيفية، وتطبيع الدفعات، ودمج الطبقات، وإسقاط الطبقات (Dropout). حققت النتائج دقة 95.82% لمجموعة DRIVE، و96.72% لمجموعة STARE، و96.88% لمجموعة CHASE. على الرغم من نجاحها في استخراج الأوعية الدموية، إلا أن الدراسة لم تركز على تصنيف مراحل اعتلال الشبكية السكري.

أجرى Gardner وآخرون (2014) دراسة لتقييم أداء الشبكات العصبية في اكتشاف مؤشرات اعتلال الشبكية السكري مقارنةً بطبيب العيون. استخدمت الدراسة 147 صورة لمرضى السكري و32 صورة لأشخاص طبيعيين للتدريب، و200 صورة لمرضى السكري و101 صورة لأشخاص طبيعيين

للاختبار. تم تحليل الصور باستخدام شبكة عصبية تعتمد على خوارزمية الانتشار العكسي. حققت الشبكة معدلات اكتشاف 91.7% للأوعية الدموية، و93.1% للإفرازات، و73.8% للنزيف. مقارنةً بطبيب العيون، حققت الشبكة حساسية 88.4% ونوعية 83.5%. تشكلت هذه الدراسة إحدى الدراسات المبكرة في هذا المجال، لكنها اعتمدت على مجموعة بيانات محدودة نسبياً.

استخدم Adarsh و (2013) Jeyakumari تقنيات معالجة الصور لتطوير نظام تشخيص تلقائي لاعتلال الشبكية السكري، من خلال كشف الأوعية الدموية، والإفرازات، والتمددات الدقيقة، والسمات النسيجية. تم استخدام مساحات الآفات والسمات النسيجية لبناء متجه السمات الذي تم إدخاله إلى آلة دعم المتجهات متعددة الفئات (multiclass SVM). حقق النظام دقة 96% على قاعدة البيانات DIARETDB0 (89 صورة) و94.6% على قاعدة البيانات DIARETDB1 (130 صورة). تُعد هذه الدراسة مثالاً على استخدام تقنيات معالجة الصور التقليدية قبل انتشار تقنيات التعلم العميق.

قام Acharya وآخرون (2009) بتطوير طريقة تصنيف لخمس فئات من اعتلال الشبكية السكري، من خلال حساب مساحات السمات مثل النزيف، التمددات الدقيقة، الإفرازات، والأوعية الدموية. تم استخراج هذه السمات من الصور الخام باستخدام تقنيات معالجة الصور، ثم إدخالها إلى آلة دعم المتجهات (SVM) للتصنيف. حقق النظام حساسية 82%، ونوعية 86%، ودقة 85.9%. أشار الباحثون إلى أن الانخفاض في الحساسية والنوعية يعود إلى الطبيعة المعقدة لتصنيف خمس فئات. تُعد هذه الدراسة من الدراسات المبكرة التي ركزت على تصنيف خمس فئات، لكنها اعتمدت على مجموعة بيانات صغيرة.

اقترح Garcia وآخرون (2017) استخدام شبكات CNN مثل AlexNet و VGGNet16 لتصنيف صور العين اليمنى واليسرى بشكل منفصل. شملت مرحلة المعالجة المسبقة تحسين تباين الصور وتوسيع البيانات. حقق النموذج دقة 93.65%، وحساسية 54.47%، ودقة إجمالية 83.68%.

ومع ذلك، لم تقم الدراسة بتصنيف مراحل اعتلال الشبكية السكري بشكل محدد، بل ركزت على اكتشاف وجود المرض من عدمه.

المنهجية:

4.1 مجموعة البيانات وتحضيرها

استخدمنا مجموعة بيانات APTOS 2019 Blindness Detection التي تحتوي على 3,662 صورة لشبكية العين، مصنفة إلى خمس فئات تمثل درجات مختلفة من شدة اعتلال الشبكية السكري:

- الدرجة 0: (No_DR) عين سليمة (1,805 صورة)
 - الدرجة 1: (Mild) اعتلال خفيف (370 صورة)
 - الدرجة 2: (Moderate) اعتلال متوسط (999 صورة)
 - الدرجة 3: (Severe) اعتلال شديد (193 صورة)
 - الدرجة 4: (Proliferative) اعتلال تكاثري (295 صورة)
- كما يتضح من التوزيع، توجد مشكلة واضحة بعدم توازن الفئات، حيث تمثل الفئة 0 (العين السليمة) حوالي 49.3% من البيانات، بينما تمثل الفئة 3 (الاعتلال الشديد) فقط 5.3% من البيانات. لمعالجة هذه المشكلة، قمنا بتطبيق تقنيات متقدمة لتحسين البيانات (Data Augmentation) تشمل:

- تدوير الصور بزوايا عشوائية (0° إلى 30°)
- تغيير السطوع والتباين بشكل عشوائي
- قلب الصور أفقيًا

- تطبيق تقنية CLAHE (Contrast Limited Adaptive Histogram Equalization)

لتحسين جودة الصور

- تغيير حجم الصور إلى 299×299 بكسل لتتناسب مدخلات شبكة Xception

2.4 معمارية النموذج المقترح

النموذج المقترح يعتمد على هيكلية محسّنة من شبكة Xception مع التعديلات التالية:

1. الطبقة الأساسية: استخدام Xception بدون الطبقات العلوية مع الأوزان المدربة مسبقاً على

ImageNet


2. طبقة: Global Average Pooling 2D لاستخراج السمات المكانية المهمة مع تقليل الأبعاد

3. طبقتي Dropout متكيفتين: استخدام Dropout بنسبة 50% مع آلية تكيف ديناميكية تعتمد

على نسبة التوازن بين الفئات

4. طبقة كثيفة 2048: (Dense) وحدة مع دالة تنشيط ReLU وتنبثق L2 بمعامل 0.001

5. طبقة الإخراج 5: وحدات مع دالة تنشيط Softmax لتصنيف متعدد الفئات



الشكل 1 يوضح معمارية النموذج المقترح:

5. استراتيجية التدريب

لتدريب النموذج المقترح، استخدمنا المعايير التالية:

- دالة الخسارة: دالة خسارة موزونة (Weighted Cross-Entropy) لمعالجة عدم توازن الفئات
- المُحسّن Adam: مع معدل تعلّم ابتدائي 0.0001 وتخفيض تدريجي (Learning Rate Scheduling)
- Early Stopping: مع مراقبة Validation Loss لمدة 15 عصر (Epoch) بدون تحسن
- تقييم الأداء: باستخدام مقاييس متعددة: الدقة (Accuracy)، F1-Score، المرجح، AUC-ROC، ومصفوفة الارتباك

لحساب دالة الخسارة الموزونة، استخدمنا الصيغة التالية:

$$\text{Weight} = n_i \times CN$$

حيث:

- N هو إجمالي عدد العينات
- n_i هو عدد العينات في الفئة i
- C هو عدد الفئات


6 النتائج والمناقشات

1.6 الأداء الكلي

حقق النموذج المقترح نتائج ممتازة مقارنة بالدراسات السابقة:

- دقة التدريب: 98.63%
- دقة التحقق: 95.20%
- F1-Score المرجح: 94.8%
- فقدان التحقق (Validation Loss): 0.1749


أظهر منحنى الدقة الموضح في (الشكل 2) تحسناً ثابتاً على مدار 50 عصر تدريب، مع تقارب جيد بين أداء التدريب والتحقق، مما يدل على أن النموذج لا يعاني من فرط التعلم (Overfitting) أو نقص التعلم (Underfitting).



الشكل 2: منحنى الدقة

2.6 تحليل مصفوفة الارتباك

كشف تحليل مصفوفة الارتباك (الشكل 3) عن أداء متميز في تصنيف الفئات الرئيسية، مع بعض الصعوبات في التمييز بين الدرجات المتجاورة) مثل Moderate و Mild ، وهو ما يتوافق مع التحديات السريرية الحقيقية في التمييز بين هذه الدرجات.



من مصفوفة الارتباك يمكن حساب المقاييس التالية لكل فئة:

الجدول رقم 1: يوضح معيار التصنيف

الفئة	الدقة	الحساسية	النوعية	F1-SCORE
No_DR	96.2%	94.7%	97.1%	95.4%
Mild	92.5%	88.1%	94.3%	91.2%
Moderate	93.8%	91.5%	95.2%	92.7%
Severe	89.2%	85.0%	92.1%	87.0%
Proliferative	91.9%	88.5%	93.6%	91.0%

من الجدول أعلاه، نلاحظ أن النموذج أظهر أداءً جيدًا حتى على الفئات الأقل تمثيلًا (Severe) و(Proliferative)، مما يدل على فعالية تقنيات معالجة عدم توازن الفئات التي تم تطبيقها.

7. مقارنة مع الدراسات السابقة

للمقارنة العادلة مع الدراسات السابقة، قمنا بتدريب نماذج مماثلة على نفس مجموعة بيانات APTOS 2019. تظهر النتائج في الجدول التالي:

الجدول رقم 2 يوضح مقارنة بين النتائج:

الدراسة	الدقة	F1-SCORE	ملاحظات
هذه الدراسة	95.20%	94.8%	معالجة متطورة لعدم توازن الفئات
Xception نموذج أساسي	92.75%	91.3%	بدون معالجة لعدم توازن الفئات
ResNet50 نموذج	93.10%	92.0%	مع دالة خسارة موزونة
Zhang et al. (2019)	-	-	على مجموعة بيانات مختلفة
Harry et al. (2016)	75.00%	-	بدون معالجة لعدم توازن الفئات

توضح هذه المقارنة أن النموذج المقترح يتفوق على النماذج البديلة عند تطبيقها على نفس مجموعة البيانات، مما يؤكد فعالية التعديلات التي أجريناها على معمارية Xception.

8 الخاتمة والتوصيات

1.8 الاستنتاجات

في ختام هذا البحث، نؤكد أن النموذج المقترح يمثل تقدمًا ملحوظًا في استخدام تقنيات التعلم العميق لتشخيص اعتلال الشبكية السكري. من خلال الهيكلية المحسنة لشبكة Xception وتقنيات معالجة عدم توازن الفئات، تمكن النموذج من تحقيق أداء عالي مع دقة تحقق بلغت 95.20%، مما يجعله أداة واعدة لدعم الأطباء في التشخيص المبكر والدقيق.

تبرز أهمية هذه الدراسة في تقديم حل عملي لمشكلة عدم توازن الفئات في التصنيف الطبي، وهي مشكلة تواجه العديد من التطبيقات في مجال الرعاية الصحية. وتشير النتائج إلى أن النهج المقترح يمكن تطبيقه على مهام تصنيف طبية أخرى، مما يفتح آفاقًا جديدة للبحث في هذا المجال.

2.8 التوصيات

بناءً على التجربة البحثية والنتائج التي تم تحقيقها، نوصي بما يلي:

1. تحسين النموذج عبر دمج تقنيات الانتباه (Attention Mechanisms) لتحسين أداء النموذج في تحديد المناطق الحرجة في صور الشبكية
 2. استخدام تقنيات التعلم شبه المراقب (Semi-supervised Learning) لاستغلال البيانات غير المصنفة المتاحة في المجال الطبي
 3. استكشاف تقنيات التفسيرية (Explainable AI) لزيادة شفافية النموذج وبناء الثقة لدى الأطباء
 4. تطبيق النموذج على مجموعات بيانات متعددة المراكز (Multi-center Datasets) لاختبار قدرة التعميم عبر مصادر بيانات مختلفة
- في المستقبل، نخطط لتطوير هذا النموذج لدمج تقنيات الانتباه وزيادة تفسيرية النموذج، مما سيساهم في بناء أنظمة تشخيص طبي أكثر دقة وموثوقية تعتمد على الذكاء الاصطناعي.

المراجع

- [1] World Health Organization, "Diabetes," 2021. [Online]. Available: <https://www.who.int/news-room/fact-sheets/detail/diabetes>
- [2] P. Harry, C. Frans, and M. Deborah, "Convolutional neural networks for diabetic retinopathy," Procedia Computer Science, vol. 90, pp. 200-205, 2016.
- [3] S. Mobeen, H. Khan, and S. ABBAS, "Diabetic retinopathy detection using CNN," in Proc. Int. Conf. Comput. Sci. Eng., 2019, pp. 1-6.
- [4] Y. Zhang et al., "Diabetic retinopathy detection using deep learning," IEEE Access, vol. 7, pp. 129379-129388, 2019.

- [5] X. Li, X. HU, and L. YU, "Cross-disease attention network for joint diabetic retinopathy and diabetic macular edema grading," IEEE Transactions on Medical Imaging, vol. 39, no. 9, pp. 2948-2958, 2020.
- [6] V. Gulshan et al., "Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs," JAMA, vol. 316, no. 22, pp. 2402-2410, 2016.
- [7] M. E. D. Garcia, J. D. Gallardo, and J. D. Mauricio, "Detection of diabetic retinopathy based on a convolutional neural network using retinal fundus images," in Proc. Int. Conf. Artif. Neural Netw., 2017, pp. 635-642.
- [8] A. Adarsh and P. Jeyakumari, "Multiclass SVM-based automated diagnosis of diabetic retinopathy," in Proc. Int. Conf., 2013, pp. 206-210.
- [9] U. R. Acharya, C. M. Lim, and E. Y. K. Ng, "Computer-based detection of diabetes retinopathy stages using digital fundus images," Proceedings of the Institution of Mechanical Engineers, Part H: Journal of Engineering in Medicine, vol. 223, no. 5, pp. 545-553, 2009.
- [10] G. G. Gardner et al., "Automatic detection of diabetic retinopathy using," British Journal of Ophthalmology, vol. 78, no. 5, pp. 360-363, 1994.