

دراسة استقصائية حول نماذج التنبؤ بمرض القدم السكرية القائمة على الذكاء الصناعي وطرق معالجة الصور

سوزان يعقوب* د. محسن الحسين** د. رامز الخطيب***

(الإيداع: 22 كانون الأول 2021، 26 آذار 2022)

الملخص:

يلعب التعلم الآلي دوراً مهماً في العديد من جوانب الرعاية الصحية، من التشخيص إلى العلاج وحتى إلى علم الأوبئة. وحتى وقت قريب جداً، كان الطب يعتمد فقط على الخبرة المهنية التي يحصلها الأطباء. ولكن مع النمو في حجم قواعد البيانات أصبحت تطبيقات الذكاء الاصطناعي أكثر حضوراً، وباتت الفوائد المتأتية من تطبيق التعلم الآلي في الطب أكثر شهرة .

مرض السكري هو أحد الأمراض الشائعة جداً وأخذت حيزاً مهماً في الطب. إنه مرض استقلابي حيث تؤدي الإدارة غير السليمة لمستوى الجلوكوز في الدم إلى خطر الإصابة بالعديد من الأمراض مثل أمراض وتقرحات القدم وبتر الأعضاء وما إلى ذلك.

يُعدّ تفرح القدم السكرية والبتير سبباً في حدوث اعتلال كبير. يمكن تحقيق الوقاية من القدم السكرية من خلال تحديد المرضى المعرضين لخطر الإصابة ووضع تدابير وقائية.

كان هناك قدر كبير من الأبحاث التي تشمل طرق الكمبيوتر والتكنولوجيا للكشف والتعرف على قرح القدم السكرية ، ولكن هناك نقص في المقارنات المنهجية لأحدث ما توصلت إليه التكنولوجيا.

في هذا البحث ، سنقدم عدة دراسات قامت من أجل الكشف المبكر عن القدم السكرية باستخدام معالجة الصور والتعلم الآلي ونقوم بمقارنة النتائج.

اعتماداً على مشاكل الدراسات السابقة قدمنا طريقة عمل جديدة .

ومن خلال النتائج التجريبية التي قمنا بها باستخدام الطريقة المقترحة نستطيع أن نلاحظ التحسن الكبير في دقة وصحة النتائج مقارنة بالدراسات السابقة.

*طالبة دراسات عليا (ماجستير) – اختصاص برمجيات ونظم معلومات – كلية الهندسة المعلوماتية – جامعة البعث

**دكتور في هندسة المعلوماتية اختصاص برمجيات ونظم معلومات –جامعة البعث

***دكتور في هندسة المعلومات علوم الحاسوب – الكلية التطبيقية – جامعة حماه

A survey of artificial intelligence–based diabetic foot disease prediction models and image processing methods

Souzan yaacoub* Dr. Mohseen Alhseen Dr. Ramez Alkhatib*****

(Received: 22 December 2021, Accepted: 26 March 2022)

Abstract:

Machine learning plays a dominant role in many aspects of health care, from diagnosis to treatment and even to epidemiology. Until very recently, medicine relied solely on the professional expertise of physicians. But with the growth in the size of databases, the applications of artificial intelligence became more present, and the benefits of applying machine learning in medicine became more and more famous.

Diabetes is one of the very common diseases and has taken an important place in medicine. It is a metabolic disease where improper management of blood glucose level leads to the risk of many diseases like foot diseases, ulcers, amputations, etc.

Diabetic foot ulcers and amputation are major morbidity. Prevention of diabetic foot can be achieved by identifying patients at risk and putting in place preventive measures.

There has been a great number of research involving computer and technology methods for detecting and identifying diabetic foot ulcers, but there is a lack of systematic comparisons of state-of-the-art technology.

In this paper, we will present several studies conducted for early detection of diabetic foot using image processing and machine learning and compare the results.

Based on the problems of previous studies, we presented a new method of work.

Through the experimental results that we carried out using the proposed method, we can note the significant improvement in the accuracy and validity of the results compared to previous research.

*Master Student (Master) – Specialization in Software and Information Systems – College of Informatics Engineering – Al-Baath University

**Doctor of Informatics Engineering, specializing in software and information systems – Al-Baath University

***Doctor of Information Engineering Computer Science – Applied College – University of Hama

1-مقدمة:

إن انتشار الأمراض يهدد الصحة والاقتصاد والأمن ، مما يحتم علينا أن نعطي الأمراض بمختلف أنواعها الكثير من الوقت والجهد لتلافي مخاطرها.

هناك العديد من الأمراض التي تستحق أن تكون في طليعة الدراسات لتشخيصها وعلاجها ، سنركز في هذا البحث على مرض السكري.

مرض السكري هو مشكلة صحية عامة رئيسية تتزايد بشكل كبير .

وفقاً للاتحاد الدولي للسكري [1]، في عام 2019 ، كان هناك ما يقرب من 463 مليون بالغ (20-79 عاماً) مصابين بداء السكري في جميع أنحاء العالم. ومن المتوقع أن يرتفع هذا الرقم إلى 700 مليون بحلول عام 2045 ، تسبب مرض السكري في وفاة 4.2 مليون شخص ، ومرض السكري هو السبب الرئيسي السابع للوفاة في الولايات المتحدة [7].

هناك نوعان من مرض السكري:

داء السكري من النوع الأول:

ينتج البنكرياس القليل جداً من الأنسولين أو لا ينتج الأنسولين. لذلك ، يجب أن يتلقى الشخص المصاب بداء السكري من النوع الأول الأنسولين يومياً طوال حياته.

داء السكري من النوع الثاني:

يعد مرض السكري من النوع الثاني أكثر أنواع مرض السكري شيوعاً ، حيث يمثل حوالي 90% من جميع حالات السكري ، ويتميز بشكل عام بمقاومة الأنسولين ، حيث لا يستجيب الجسم للأنسولين بشكل كامل. نظراً لأن الأنسولين لا يعمل بشكل صحيح ، تستمر مستويات الجلوكوز في الدم في الارتفاع ، وتطلق المزيد من الأنسولين. بالنسبة لبعض الأشخاص المصابين بداء السكري من النوع 2 ، يمكن أن يؤدي هذا في النهاية إلى استنفاد البنكرياس ، مما يؤدي إلى إنتاج الجسم كميات أقل وأقل من الأنسولين ، مما يؤدي إلى ارتفاع مستويات السكر في الدم (ارتفاع السكر في الدم).

يتم تشخيص مرض السكري من النوع 2 بشكل أكثر شيوعاً عند كبار السن ، ولكنه يُلاحظ بشكل متزايد عند الأطفال والمراهقين والشباب بسبب ارتفاع مستويات السمنة وقلة النشاط البدني وسوء التغذية ، وتؤثر الأمراض المرتبطة بالسكري من النوع 2 بشكل رئيسي على العينين والكلَى والقدمين.

سنركز في هذا العمل على آثار مرض السكري من النوع الثاني على القدم (القدم السكرية) ، إصابات القدم السكرية هي اعتلال الأعصاب المحيطية وهو فقدان الإحساس بالقدم ، يعني أنك لا تشعر بأي ألم ، حتى لا تترك الإصابات التي يمكن أن تحدث داخلياً والاعتلال الوعائي المعروف بنقص الإحساس تدفق الدم [11] ، وذلك بسبب الزيادة المستمرة في نسبة الجلوكوز في الدم مما يؤدي إلى تضيق بعض الأوعية الدموية الصغيرة التي تروي القدم مما يؤدي إلى عدم وصول الأكسجين والعناصر الغذائية الأساسية إلى القدم ، نتيجة لانخفاض تدفق الدم ، يجعل الجروح تستغرق وقتاً أطول للشفاء وتكون عالية الخطورة عند الإصابة [12].

فمضاعفات القدم السكرية والأطراف السفلية شديدة ومزمنة. تؤثر على 40 إلى 60 مليون شخص مصاب بمرض السكري على مستوى العالم. تؤدي القرحة المزمنة وبتر الأطراف إلى انخفاض كبير في نوعية الحياة وزيادة خطر الوفاة المبكرة ، حيث يتعرف أقل من ثلث الأطباء على علامات اعتلال الأعصاب المحيطية المرتبط بالسكري. تساهم التشخيصات المفقودة الناتجة بشكل كبير في ارتفاع معدلات المرض والوفيات ، ومن الضروري تطوير حل تكنولوجي قادر على تغيير ممارسات الفحص الحالية التي لديها القدرة على تقليل أعباء الوقت السريرية بشكل كبير. [13,14]

يستخدم التصوير الحراري لدراسة عدد كبير من الأمراض حيث يمكن أن تعكس درجة حرارة الجلد وجود التهاب في الأنسجة الكامنة أو حيث يزداد تدفق الدم أو ينقص بسبب عدم انتظام إكلينيكي.

تقدم هذه الورقة لمحة عامة عن أحدث طرق الكمبيوتر في اكتشاف قرحة القدم السكرية ، ومن ثم مقارنة هذ النتائج ومعرفة نقاط ضعف ونقاط قوة كل دراسة وفي النهاية تقديم بعض المقترحات لما اكتشفناه من هذه القراءات والدراسات.

2-هدف البحث:

تهدف هذه الدراسة إلى تسليط الضوء على مجموعة من الأبحاث والطرق المستخدمة في الكشف المبكر عن مرض القدم السكرية.

يمكن تلخيص أهداف البحث بالآتي:

- تجميع دراسات حول الاكتشاف المبكر للقدم السكرية من مصادر متنوعة وشاملة .
- اكتشاف المزايا والعيوب لكل دراسة.
- مقارنة نتائج الدراسات.
- تقديم أفضل النتائج التي تم الحصول عليها بما يخص الاكتشاف المبكر للقدم السكرية.
- بعض المقترحات التي قد تحسن من صحة ودقة الاكتشاف المبكر للقدم السكرية بناء على الدراسات والمراجع والمقارنات التي استخدمناها.


3-منهجية العمل :

3.1-الدراسات السابقة التقليدية القائمة على معالجة الصور:

الكشف التلقائي عن مضاعفات القدم السكرية باستخدام التصوير الحراري بالأشعة تحت الحمراء عن طريق التحليل غير المتماثل. [2]

تعتمد هذه الدراسة بشكل رئيسي على الفرق بدرجات الحرارة بين القدم اليسرى والقدم اليمنى. يمكن الإشارة إلى منهجية تحقيق الفروق في درجات الحرارة بين المناطق المتناظرة على القدم اليمنى واليسرى باسم "التحليل غير المتماثل". [8,9]

مخطط العمل التفصيلي كما في الشكل (1).



الشكل رقم (1): مخطط انسيابي للمنهجية المقترحة للكشف التلقائي عن مضاعفات القدم السكرية في الدراسة السابقة الأولى.


طريقة العمل بشكل عام:

1. Foot segmentation : استخراج القدم اليسرى والقدم اليمنى من الخلفية.
 2. Feet registration : ربط مناطق القدم الواحدة بالمناطق المقابلة للقدم المقابلة.
 3. Detection : قارن درجة حرارة المناطق المرتبطة إذا كان الفرق بين درجات الحرارة في منطقتين مرتبطتين أكبر من عتبة معينة ، فمن المفترض أن يكون أحد هاتين المنطقتين في خطر .
- القيود المفروضة على دراسة:

كان أحد القيود على التحليل غير المتماثل المقترح هو أنه يمكن فقط اكتشاف مضاعفات القدم السكرية من خلال مقارنة قدمي المريض. هذا يعني أنه عند بتر إحدى القدمين ، لا يمكن اكتشاف أي مضاعفات في القدم الأخرى. بالإضافة إلى ذلك ، في حالة وجود مضاعفات متشابهة في كلا القدمين في المناطق المقابلة ، سيتم أيضًا تقوية المضاعفات. قيد آخر للدراسة هو أنه لم يكن لدينا "مقياس ذهبي" لتقييم تجزئة وتسجيل القدمين. استخدمنا المراجع المقسمة يدويًا والتي تم تصنيفها بواسطة محقق طبي واحد. قد يكون هذا عرضة لبعض التحيز لأن مراقب آخر قد يأتي إلى ملاحظات مختلفة. مكان وعام الدراسة: Amsterdam, 2015 .

الكشف عن الاشتباه في القد السكرية باستخدام الصورة الحرارية. [3]


يؤكد العمل البحثي استخدام الصور الحرارية للكشف عن اشتباه في القدم السكرية بسبب الاختلاف في درجة الحرارة في القدمين. مخطط العمل التفصيلي كما في الشكل (2).



الشكل رقم (2): رسم تخطيطي لتدفق الكشف عن القدم السكرية المشتبه بها في الدراسة السابقة الثانية .

طريقة العمل بشكل عام:

1. أخذ صورة طبيعية وصورة حرارية للقدمين.
2. بالصورة الحرارية يتم فصل القدم اليسرى عن اليمنى.
3. معالجة الصور لمعرفة درجات الحرارة في كل بكسل من الصورة.
4. حساب الفرق في درجات الحرارة بين القدمين.
5. معرفة البكسلات التي الفرق بدرجات الحرارة فيها عالية وعكسها على على الصورة الطبيعية كما في الشكل (3).




الشكل رقم (3): يوضح تحديد المناطق من الصور الحرارية التي الفرق بدرجات الحرارة فيها عالية وعكسها على الصورة الطبيعية

يؤكد العمل البحثي استخدام الصور الحرارية للكشف عن الاشتباه في القدم السكرية بسبب تباين درجات الحرارة في القدمين. لمعالجة الصورة ، كانت الصورة الحقيقية والصورة الحرارية مطلوبة لأنه في نهاية العملية كان من الضروري تركيب المنطقة المجزأة للاشتباه في القدم السكرية على الصورة الحقيقية. وهذا الأمر مكلف من حيث الوقت والجهد والكلفة. هذا العمل البحثي يؤكد وجود الخلل ولكنه لا تستطيع تأكيد حالة القدم السكرية. مكان وعام الدراسة: Perú, 2019.

3.2-الدراسات السابقة التي تعتمد على معالجة الصور والذكاء الصناعي:

الكشف الآلي عن القدم السكرية باستخدام الصور الحرارية بواسطة مصنفات الشبكة العصبية.[4] مخطط العمل التفصيلي كما في الشكل (4).




الشكل رقم (4): مخطط التصنيف بحسب الدراسة المرجعية الرابعة.

طريقة العمل بشكل عام:

1. معالجة الصور الحرارية
2. تقسيم الصور
3. استخراج الميزات لكل صورة
4. التصنيف باستخدام خوارزميات تعلم الآلة.

نتائج تجريبية

تم أخذ 10 صور طبيعية و 25 صورة غير طبيعية من 6 أشخاص مصابين بداء السكري وغير مصابين بالسكري ، ويتم الحصول على المخرجات عن طريق إجراء معالجة MATLAB ، ويتم حساب الأداء والوقت المعقد للمصنفات الثلاثة. ينتج مصنف SVM دقة تصل إلى 75%. ينتج مصنف PNN دقة تبلغ 61% وتنتج KNN دقة تبلغ 95%. يوضح الشكل رقم 5 تقييم أداء المصنفات.



الشكل رقم (5): أداء المصنفات بحسب الدراسة السابقة الرابعة

الدراسة أجريت على 35 صورة فقط 25 حالة قدم سكرية و 10 طبيعية مما يعرضنا لحالة over-fitting أي هذه النتائج مناسبة لهذه البيانات فقط ولا يمكن تعميمها أو اعتمادها على بيانات جديدة أخرى.

التعلم العميق في الكشف عن تقرحات القدم السكرية: تقييم شامل . [5]

طرق الكشف المستخدمة في هذه الدراسة ، مجمعة وفقاً لخوارزميات اكتشاف كائن التعلم العميق الشائعة ، والتي تشمل Faster R-CNN و YOLOv3 و YOLOv5 و EfficientDet.

وبالتالي تم دراسة 4 طرق.

الطريق الأولى:

data augmentation

Model training and implementation

Variants of faster R-CNN

Post-processing

Ensemble method

النتائج كما في الجدول (1)

الجدول رقم (1): نتائج تطبيق إصدارات مختلفة من R-CNN بحسب الدراسة السابقة الخامسة

Method	TP	FP	Recall	Precision	F1-Score	mAP
Faster	1512	683	0.7210	0.6888	0.7046	0.6338
Cascade	1483	649	0.7072	0.6956	0.7014	0.6309
Deform	1612	628	0.7687	0.7196	0.7434	0.6940
PISA	1495	444	0.7129	0.7710	0.7408	0.6518
Ensemble	1447	394	0.6900	0.7860	0.7349	0.6353

الطريقة الثانية بشكل عام باستخدام YOLOv3:

Pre-processing

Data Augmentation

Model using YOLO3

Training

Post-processing

النتائج كما في الجدول (2).

الجدول رقم (2): النتائج باستخدام YOLO3 بحسب الدراسة المرجعية الخامسة

Method	Settings			Metrics					
	Base	Coefficient	Overlap-Removed	TP	FP	Recall	Precision	F1-Score	mAP
B50	50	0	x	1572	676	0.7496	0.6993	0.7236	0.6560
B50_Overlap	50	0	✓	1553	618	0.7406	0.7153	0.7277	0.6500
B32	32	0	x	1452	605	0.6929	0.7060	0.6994	0.6053
B32_Overlap	32	0	✓	1433	551	0.6834	0.7223	0.7023	0.5998
B32_Overlap_conf	32	0.3	✓	1386	490	0.6609	0.7388	0.6977	0.5835
B50_Exact	50	0	x	1563	616	0.7454	0.7173	0.7311	0.6548
B50_Overlap_Extra	50	0	✓	1543	565	0.7358	0.7320	0.7339	0.6484

الطريقة الثالثة بشكل عام باستخدام YOLOv5:

Pre-processing

Data Augmentation

Model using YOLO5

Training

Post-processing

النتائج كما في الجدول (3).

الجدول رقم (3): النتائج باستخدام YOLO5 بحسب الدراسة السابقة الخامسة

Method	Settings			Metrics					
	Base	Self-training	TTA + NMS	TP	FP	Recall	Precision	F1-Score	mAP
E60_SELF90	60	30	x	1504	474	0.7172	0.7604	0.7382	0.6270
E60_SELF100	60	40	x	1496	485	0.7134	0.7552	0.7337	0.6165
E60_SELF100_TTA_NMS	60	40	✓	1507	498	0.7187	0.7516	0.7348	0.6294
E60_SELF120	60	60	x	1502	478	0.7163	0.7586	0.7368	0.6201

الطريقة الرابعة بشكل عام باستخدام EfficientDet:

Pre-processing

Data augmentation

Model using efficientDet

Training

Post-processing

النتائج كما في الجدول (4).

الجدول رقم (4): النتائج باستخدام YOLO5 بحسب الدراسة السابقة الخامسة

Methods	TP	FP	Recall	Precision	F1-Score	mAP
Before	1626	770	0.7754	0.6786	0.7238	0.5782
After	1593	594	0.7597	0.7284	0.7437	0.5694

مرض السكري باستخدام خوارزميات التعلم الآلي. [6]

الهدف الأساسي من هذا المشروع هو تحليل مجموعة بيانات مرض السكري واستخدام الانحدار اللوجستي ، وآلة المتجهات الداعمة ، وخوارزميات Naïve Bayes ، وخوارزميات K-Nearest Neighbours للتنبؤ وتطوير محرك تنبؤ. الهدف الثانوي هو تطوير تطبيق ويب بالميزة التالية.

- طريقة العمل بشكل عام:
- تحويل البيانات إلى تنسيق مناسب
- معالجة البيانات
- استخدام التعلم الآلي لمعالجة البيانات
- و النتائج كما في الجدول (5).

الجدول رقم (5) : دقة خوارزميات التعلم الآلي بحسب الدراسة السابقة السادسة

Classification Algorithms	Precision
Naive Bayes	0.72
Decision Tree	0.68
SVM	0.62
KNN	0.66

4-دراسة استقصائية وتحليل النتائج:

بناء على ما ذكرناه من دراسات سابقة سنقوم ببعض المقارنات بناء على مصدر و حجم قاعدة البيانات المستخدمة ونقاط الضعف في كل بحث بالإضافة إلى مكان وعام الذي تم فيه البحث و من ثم سنعطي النتائج المستخلصة من هذه المقارنات .

4.1 المقارنات:

الكشف التلقائي عن مضاعفات القدم السكرية باستخدام التصوير الحراري بالأشعة تحت الحمراء عن طريق التحليل غير المتماثل. [2]

اعتمدت هذه الدراسة على بعض الصور الحرارية المأخوذة بشكل يدوي من قبل الباحثين باستخدام IR camera ولم يتم ذكر عدد الصور بشكل دقيق .
نقطة الضعف الرئيسية في هذه الدراسة عدم القدرة على تحديد وجود المرض في حالات بتر او تشوه مسبق في القدم وبالتالي النتائج ليست بدقة جيدة.

الدراسة أجريت في University of Amsterdam, 2015

الكشف عن الاشتباه في القدم السكرية باستخدام الصورة الحرارية. [3]

اعتمدت هذه الدراسة على مجموعة من الصور الحرارية والطبيعية المأخوذة من Podiatric Center في جنوب افريقيا (15 حالة).

نقطة الضعف الرئيسية أنه يؤكد هذا العمل وجود شيء خاطئ ولكن لا يمكن تأكيد حالة القدم السكري .
بالإضافة إلى ذلك ، فقد أجريت الدراسة على 15 شخصاً فقط ، مما يجعلنا نشك في صحة ودقة نتائج هذا البحث والنتائج معرضة لحالة over-fitting عالية، أي هذه النتائج مناسبة لهذه البيانات فقط ولا يمكن تعميمها اواعتمادها على بيانات جديدة أخرى. حيث لم يتم وضع أي دليل في البحث يثبت عدم وجود over-fitting.

الدراسة أجريت في Perú, 2019

الكشف الآلي عن القدم السكرية باستخدام الصور الحرارية بواسطة مصنفاة الشبكة العصبية. [4]

اعتمدت هذه الدراسة على صور حرارية مأخوذة بشكل يدوي (35 حالة).
نقطة الضعف الرئيسية الدراسة أجريت على 35 صورة فقط 25 حالة قدم سكرية و 10 طبيعية مما يعرضنا لحالة over-fitting أي هذه النتائج مناسبة لهذه البيانات فقط ولا يمكن تعميمها اواعتمادها على بيانات جديدة أخرى. حيث لم يتم وضع أي دليل في البحث يثبت عدم وجود over-fitting.

الدراسة أجريت في India, 2017

التعلم العميق في الكشف عن تقرحات القدم السكرية: تقييم شامل . [5]

اعتمدت هذه الدراسة على جمع الصور (صور طبيعية) من مستشفيات لانكشاير التعليمية خلال عدد من السنوات، تتكون مجموعة البيانات من 4000 صورة ، مع 2000 مستخدمة لمجموعة التدريب و 2000 مستخدمة لمجموعة الاختبار .

نقطة الضعف الرئيسية أنه حققت R-CNN أفضل دقة (0.6940) وحققت طريقة Ensemble أفضل نتيجة من خلال مقياس f1 بمقدار 0.7434 في اكتشاف القدم السكرية على مجموعة البيانات. يمكننا أن نرى أن هذه النتيجة في الطب ليست جيدة جدًا وعلينا تحسين الدقة سواء كانت دقة أو F1 – SCORE أو أي مقياس آخر من مقاييس الدقة.

أجريت الدراسة في UK, Germany, New Zealand, 2021

تشخيص مرض السكري باستخدام خوارزميات التعلم الآلي. [6]

اعتمدت هذه الدراسة على مجموعة بيانات لصور (صور طبيعية) من 15000 حالة تم جمعها من المعهد الوطني للسكري وأمراض الجهاز الهضمي والكلية في الهند.

نقطة الضعف الرئيسية أنه يظهر التصنيف مع Naïve Bayes أفضل دقة بنسبة 0.72%.

يمكننا أن نرى أن هذه النتيجة في الطب ليست جيدة جدًا وعلينا تحسين الدقة .

أجريت الدراسة في India, 2019.

4.2 تحليل النتائج:

من خلال الدراسات السابقة والمقارنات السابقة نلاحظ تأثير حجم قاعدة البيانات على صحة ودقة النتائج. Overfitting هو في الأساس تعلم الارتباطات الزائفة التي تحدث في بيانات التدريب ، ولكن ليس في العالم الحقيقي. يجب أن تؤدي زيادة حجم مجموعة البيانات إلى تقليل هذه الارتباطات الزائفة وتحسين أداء المتعلم. حيث كلما زاد حجم قاعدة البيانات كلما انخفض الارتباط الزائف (overfitting) وبالتالي كلما زادت الدقة. أيضا نلاحظ تنوع الوسائل في الكشف المبكر عن القدم السكرية ، حيث بعض الدراسات تستخدم معالجة الصور فقط سواء صور طبيعية أو حرارية ، وبعض الدراسات استخدمت الذكاء الصناعي كخوارزميات التعلم الآلي والتعلم العميق . الدمج بين معالجة الصور مع خوارزميات التعلم الآلي والعميق المختلفة سوف يؤدي إلى نتائج أفضل. أيضا نلاحظ أهمية هذا الموضوع الذي قامت العديد من الدراسات حوله منذ سنوات ولا زالت مستمرة إلى اليوم للوصول إلى دقة جيدة في النتائج ، وبالتالي تشخيص القدم السكرية بشكل مبكر وحماية القدم من التقرحات أو حتى البتر من أهم المواضيع المطروحة حاليا والتي يجب أن تبنى العديد من الدراسات حولها.


5- الطريقة المقترحة:

5.1- مشكلة البحث الأساسية:

الدراسات السابقة التي قامت بهدف الكشف المبكر عن القدم السكرية اعتمادا على الصور الحرارية أو الطبيعية تعاني من مشكلتين أساسيتين

إما الدقة غير كافية أو أن الدقة جيدة ولكن مع ذلك لا يوجد دليل ضمن الأبحاث على عدم وجود حالة ال overfitting وعليه نقترح هذه الطريقة التي تهدف إلى تجنب مشاكل الدراسات السابقة وتحسن الدقة وال overfitting بشكل رئيسي مع وضع مخططات الخسارة والدقة كدليل على صحة النتائج.

مخطط العمل كما في الشكل 6 :



الشكل رقم (6) : مخطط العمل

5.2-البيانات المستخدمة

سوف يتم تنفيذ المخطط على مجموعة البيانات مأخوذة من

Institute of Electrical and Electronics Engineers (IEEE)

تحتوي مجموعة البيانات على صور حرارية للأقدام من 180 شخصاً مصابين بالقدم السكرية وغير مصابين بالقدم السكرية. حيث سنقوم بتقسيم كل صورة إلى صورتين القدم اليسرى والقدم اليمنى ثم سنقوم بقلب جميع صور القدم اليسرى أفقياً وبالتالي ستصبح لدينا قاعدة بيانات لصور جميعها كصور القدم اليمنى.

5.3- بيئة العمل:

منصة العمل المستخدمة Jupyter Notebook

اللغة المستخدمة python 3.7

المكتبات الرئيسية المستخدمة من أجل خوارزميات التعلم العميق هي tensorflow 1.14.0 و

keras 2.3.1 .

سنقوم بتطبيق خوارزميات التعلم العميق (خوارزمية cnn بإصدارات مختلفة) على قاعدة البيانات الجديدة بعد المعالجة .

سنستخدم أسلوب التعلم بالنقل ولكن مع إعادة تدريب للأوزان ومع وضع طبقة الاتصال الكامل الخاصة بنا.

قمنا بتطبيق 7 إصدارات مختلفة من خوارزمية cnn هي:

- Resenet50
- MobilNet
- MobilNetV2
- nceptionV3
- Xception
- Vgg16
- Vgg19

5.4-نتائج الطريقة المقترحة:

النتائج التي حصلنا عليها بتطبيق الخوارزميات التي ذكرناها هي كما في الجدول التالي:

الجدول رقم (6) : نتائج تطبيق 7 إصدارات مختلفة من خوارزمية cnn

Network	Class	Precision	Recall	F1-scoe	Accuracy
Resenet50	DM	0.69	1.00	0.82	0.69
	CG	0.00	0.00	0.00	
	Macro avg	0.35	0.50	0.41	
MobilNet	DM	0.83	1.00	0.91	0.85
	CG	1.00	0.33	0.50	
	Macro avg	0.87	0.85	0.81	
MobilNetV2	DM	0.68	1.00	0.81	0.76
	CG	1.00	0.08	0.14	
	Macro avg	0.84	0.54	0.48	
InceptionV3	DM	0.72	0.96	0.82	0.74
	CG	0.86	0.40	0.55	
	Macro avg	0.79	0.68	0.69	
Xception	DM	0.64	1.00	0.78	0.68
	CG	0.00	0.00	0.00	
	Macro avg	0.32	0.50	0.39	
Vgg16	DM	0.87	0.96	0.91	0.87
	CG	0.89	0.67	0.76	
	Macro avg	0.88	0.82	0.84	
Vgg19	DM	0.90	1.00	0.96	0.93
	CG	0.94	0.86	0.90	
	Macro avg	0.92	0.93	0.93	

حيث DM ترمز إلى فئة Diabetes Mellitus أي وجود مرض السكري في القدم
و CG ترمز إلى فئة Control Group أي عدم وجود مرض السكري في القدم.

من خلال تجاربنا السابقة نستطيع أن نلاحظ أن خوارزمية vgg19 أعطت أفضل النتائج بالنسبة لمتوسط جميع المقاييس مقارنة بباقي الخوارزميات ولكن مع ذلك هناك اختلاف بمقاييس الدقة بالنسبة للفئات (وجود القدم سكرية ، عدم وجود القدم السكرية) وهذا يدل على حالة overfitting

لذلك الخوارزمية بحاجة لمعايير البارامترات الفائقة لتخفيض ال overfitting وزيادة الدقة وهنا يأتي جوهر هذا البحث. طبقات خوارزمية vgg19 هي على الترتيب التالي:

```
0 input_1
1 block1_conv1
2 block1_conv2
3 block1_pool
4 block2_conv1
5 block2_conv2
6 block2_pool
7 block3_conv1
8 block3_conv2
9 block3_conv3
10 block3_conv4
11 block3_pool
12 block4_conv1
13 block4_conv2
14 block4_conv3
15 block4_conv4
16 block4_pool
17 block5_conv1
18 block5_conv2
19 block5_conv3
20 block5_conv4
21 block5_pool
22 flatten_1
```

بعد مئات من التجارب لمعايير البارامترات الفائقة لخوارزمية vgg19 بهدف تحسين الدقة وتحسين ال overfitting والتي هي الهدف الأساسي من هذا البحث تم الوصول إلى أفضل النتائج عند:

Batch size=16

Learning Rate=1e-5

validation_split = 0.15

test_size = 0.15

optimizer=Adam


وبالنسبة لطبقة الاتصال الكاملة كانت أفضل النتائج عند إضافة أربع طبقات هي على الشكل التالي:

الطبقة الأولى تحتوي 512 عصبون مع تابع relu
الطبقة الثانية تحتوي 512 عصبون مع تابع relu
الطبقة الثالثة تحتوي 512 عصبون مع تابع relu
الطبقة الرابعة تحتوي 1 عصبون مع تابع sigmoid
وأفضل نتيجة كانت لدينا هي كما في الجدول التالي:


الجدول رقم(7): النتائج النهائية بعد التحسين والمعايرة

Network	Class	Precision	Recall	F1–score	Accuracy
Vgg19	DM	0.96	0.96	0.96	0.94
	CG	0.91	0.91	0.91	
	macro avg	0.94	0.94	0.94	

ومخططات الخسارة والدقة هي كما في الشكل التالي:



الشكل رقم (7) : مخطط الخسارة بالنسبة لبيانات التدريب وبيانات التحقق



الشكل رقم(8):مخطط الدقة بالنسبة لبيانات التدريب وبيانات التحقق

من خلال نتائج مقاييس الدقة و مخططات الدقة والخسارة الشكل (7) والشكل (8) نستطيع ملاحظة التحسن الكبير جدا في حالة ال overfitting وهذا ما يؤكد صحة ودقة النتائج التي أعطتها خوارزمية vgg19 بعد المعايرة.

6-الخاتمة :

يهدف هذا البحث إلى تعزيز الجهود البحثية في الكشف عن قرحة القدم السكرية. حيث قدمنا ملخص عن أهم الدراسات التي قامت بغرض التشخيص المبكر للقدم السكرية بالإضافة لشرح خطوات عمل وتوضيح بعض الميزات ونقاط الضعف لكل دراسة. وبناء على ما اكتشفناه من الدراسات السابقة قدمنا طريقة عمل جديدة تهدف للكشف المبكر عن القدم السكرية اعتمادا على الصور الحرارية وخوارزميات التعلم العميق . تتجنب هذه الطريقة المقترحة مشاكل الدراسات السابقة وتقدم نتائج أفضل من حيث الدقة وصحة النتائج.

7-المراجع:

1. P. Saeedi, I. Petersohn, P. Salpea, B. Malanda, S. Karuranga, N. Unwin, S. Colagiuri, L. Guariguata, A.A. Motala, K. Ogurtsova, J.E. Shaw, D. Bright, R. Williams, Global and regional diabetes prevalence estimates for 2019 and projections for 2030 and 2045: results from the international diabetes federation diabetes atlas, 9th edition. Diabetes Research and Clinical Practice 157 (2019) 107843, <https://doi.org/10.1016/j.diabres.2019.107843>.
2. Chanjuan Liu, Jaap J. van Netten, Jeff G. van Baal, Sicco A. Bus, Ferdi van der Heijden, (February 2015), Automatic detection of diabetic foot complications with infrared thermography by asymmetric analysis, Journal of Biomedical Optics 20(2), 026003 .
3. Brian Meneses–Claudio¹, Witman Alvarado–Díaz², Fiorella Flores–Medina³ Natalia I. Vargas–Cuentas⁴, Avid Roman–Gonzalez⁵, (No. 6, 2019), Detection of Suspicious of Diabetic Feet using Thermal Image, (IJACSA) International Journal of Advanced Computer Science and Applications, Vol. 10.
4. S. Purnima, Shiny Angelin. P, Priyanka. R, Subasri. G, Venkatesh. R, (2017), Automated Detection of Diabetic Foot Using Thermal Images by Neural Network lassifiers. openaccess journal 2348–9480 .
5. Moi Hoon Yap , Ryo Hachiuma , Azadeh Alavi , Raphael Brüngel, Bill Cassidy , Manu Goyal , Hongtao Zhu , Johannes Rückert , Moshe Olshansky , Xiao Huang , Hideo Saito , Saeed (2021), Deep learning in diabetic foot ulcers detection: A comprehensive evaluation, Computers in Biology and Medicine 135 / 104596

6. Mitesh Warke¹, Vikalp Kumar², Swapnil Tarale³, Payal Galgat⁴, D.J Chaudhari⁵, (2019), Diabetes Diagnosis using Machine Learning Algorithms, International Research Journal of Engineering and Technology (IRJET)
7. D.G. Armstrong, A.J. Boulton, S.A. Bus, Diabetic foot ulcers and their recurrence, N. Engl. J. Med. 376 (2017) 2367–2375, <https://doi.org/10.1056/nejmra1615439>
8. N. Kaabouch et al., (2011) ,Enhancement of the asymmetry–based overlapping analysis through features extraction, J. Electron. Imaging 20(1),013012.
9. N. Kaabouch, W.–C. Hu, and Y. Chen, (2011),Alternative technique to asymmetry analysis–based overlapping for foot ulceration examination: scalable scanning, J. Diabetes Metab. S5, 003.
10. The British Diabetic Association operating as Diabetes UK, a charity registered in England and Wales (no. 215199)
11. Y. García García, E. Hernández Lao, A. Hernández Soublet, J. A. Barnés Domínguez, and Z. Durán Balmaseda,,(2000),Therapeutic education on diabetes for patients with first amputation caused by diabetic foot, Rev. Cuba. Angiol. y Cirugía Vasc., vol. 17, no. 1, pp. 0.
12. J. Federico, R. Cruz, E. Bonilla Huerta, R. Cocolletzi, and J. Crispín Hernández Hernández, ,(2016),Advances in the Development of a Thermographic Image Classifier of Diabetic Foot Plant Based on Backpropagation Neural Network.
13. M.H. Yap, N.D. Reeves, A. Boulton, S. Rajbhandari, D. Armstrong, A.G. Maiya, B. Najafi, E. Frank, J. Wu, (2020), Diabetic Foot Ulcers Grand Challenge, <https://doi.org/10.5281/zenodo.3715016>.
14. M.H. Yap, N. Reeves, A. Boulton, S. Rajbhandari, D. Armstrong, A.G. Maiya, B. Najafi, E. Frank, J. Wu,(2021, 2020) ,Diabetic Foot Ulcers Grand Challenge <https://doi.org/10.5281/zenodo.3715020>.
15. W. Zhao, H. Huang, D. Li, F. Chen, W. Cheng, (2020) , Pointer defect detection based on transfer learning and improved cascade–RCNN, Sensors 20 4939 X. Zhou, D. Wang, P. Krähnenbühl, , <https://doi.org/10.3390/s20174939>.