

تشخيص أمراض القلب باستخدام تقنيات التعلم العميق

د. غادة سعد*

م. حسن عبد الرحمن**

الملخص

تعد إشارة القلب الكهربائية من أهم الإشارات الحيوية لجسم الإنسان، حيث تستطيع من خلالها الكشف عن أمراض القلب وأمراض الدورة الدموية، لذلك ظهرت دراسات وبحوث عديدة في هذا المجال تضمنت أبحاث علمية وأنظمة برمجية تم من خلالها قراءة وتحليل هذه الإشارة باستخدام تقنيات الذكاء الصناعي. يهدف البحث المقترح إلى إنشاء «شبكة عصبية التلافيفية-CNN» أحادية البعد تقوم بمعالجة الإشارات القلبية التي حصلنا عليها من قاعدة البيانات «MIT-BHA» والتي تحوي على 87554 عينة من الإشارات القلبية. تضم قاعدة البيانات 5 أصناف وهي: الإشارة الطبيعية، الانقباض الأديني غير المنتظم، الانقباض البطيني السابق لأوانه، النبضة المدمجة والتي تنتج عن تراكم عدة أمواج في حالات وجود ناظم الخطي القلبية بالإضافة لصنف يحتوي إشارات قلبية باسم إشارات غير معروفة تمت معالجة البيانات وتدريب الشبكة العصبية عليها والتي أعطت دقة وصلت إلى 96.64% بالنسبة لبيانات التدريب و96.64% بالنسبة لبيانات الاختبار وقد بينت «Confusion Matrix» أن دقة التشخيص للحالة الأولى كانت 97% وللحالة الثانية كانت 85% وللحالة الثالثة كانت 95%، للحالة الرابعة 88% وللحالة الخامسة كانت 98%.

الكلمات المفتاحية: الضجيج الغوسي، الشبكة العصبية التلافيفية CNN، مصفوفة الارتباك confusion matrix، الملائمة الزائدة Over Fitting.

* مدرس - قسم الهندسة الطبية - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين.

** مهندس طبي - قسم الهندسة الطبية - كلية الهندسة الميكانيكية والكهربائية - جامعة تشرين. hasanabdarhman123@gmail.com

Diagnosing Heart Disease Using Deep Learning Techniques

Dr. Ghada Saad*

Eng. Hasan Abdulrahman**

Abstract

The Electrocardiogram (ECG) is one of the most important body bio-signals, through which many heart and blood circulations disorders and abnormalities can be detected. So that, many studies in this field have been done like making systems that read and analyze ECG signals using artificial intelligence algorithms. This project proposes a Convolutional neural network that we build from scratch. This CNN read and process ECG signals that we get from the MIT-BHA dataset. This dataset contains about 87554 ECG samples.

Samples are sorted in 5 classes, Normal beats, Supraventricular ectopic beats, Ventricular ectopic beats, Fusion beats and Unknown beats. Signals were processed and used in our CNN training and testing procedure. The confusion matrix derived from the testing dataset indicated 97% accuracy for 'normal' class. For the "Supraventricular ectopic beats" class, ECG segments were correctly classified 85% of the time. For the "Ventricular ectopic beats" class, ECG segments were correctly classified 95% of the time. For the "Fusion beats" class, ECG segments were correctly classified 88% of the time. Finally for the "Unknown Beats" class, ECG segments were correctly classified 98% of the time. In total, there was an average classification accuracy of 96.64%.

Key Words: ECG, CNN, SEB, PVC, FB, confusion matrix, Gaussian Noise.

* PhD - Biomedical Department - Faculty Mechanical and Electrical - Tishreen University.

** Biomedical Engineer - Biomedical Department - Faculty Mechanical and Electrical - Tishreen University.

hasanabdarhman123@gmail.com

1. المقدمة

خوارزمية «Support Vector Machine -SVM» من أجل التصنيف وقد أعطت النتائج بدقة وصلت إلى 97.37%، وهي دقة غير كافية مقارنة بعدد العينات القليلة المستخدمة.

في العام التالي نشرت دراسة بعنوان «Classification of Arrhythmia by Using Deep Learning with 2-D ECG Spectral Image Representation»^[4].

اقترحت هذه الدراسة تحويل الإشارات القلبية إلى صور ثنائية الأبعاد وبعد هذا تتم معالجتها بواسطة شبكة التقافة ثنائية البعد. تم استخدام قاعدة البيانات «MIT-BHI» ولكن لم تذكر الدراسة عدد العينات، وقد وصلت دقة التشخيص إلى حوالي 99.11%.

تم التركيز على الحصول على دقة عالية عن طريق تحويل الإشارة إلى صورة وبالتالي تجاهل خصائص الإشارة القلبية.

تكمن المشكلة في وجود أعداد كبيرة من الإشارات القلبية، بالإضافة إلى تعرض الإشارات للتشويش بسبب سوء تجهيز المستشفى، الأمر الذي من شأنه أن يصعب عملية تشخيص الحالة من قبل الطبيب. لهذه الأسباب قمنا ببناء شبكة عصبية التقافية لقراءة الإشارات القلبية وتشخيصها. تم الاعتماد على قاعدة بيانات تحتوي على 87554 إشارة قلبية تضم 5 أصناف وهي: الإشارة الطبيعية، الانقباض الأذيني غير المنتظم، الانقباض البطيني السابق لأوانه، النبضة المدمجة والتي تنتج عن تراكم عدة أمواج في حالات وجود ناظم الخطى القلبية بالإضافة لصنف يحتوي إشارات قلبية باسم إشارات غير معروفة.

تكمن أهمية البحث في قدرة الشبكة على قراءة عدد كبير من الإشارات وتشخيصها على الرغم من احتوائها على تشويش. الأمر الذي يساعد الطبيب في حال وجود

تعتبر الأمراض القلبية من أكثر أنواع الأمراض شيوعاً، وأكثرها مسبب للموت حول العالم. لهذا السبب عمل الباحثون عبر الزمن على تطوير طرق اقتباس الإشارة القلبية وتحسين طرق التحليل للحصول على تشخيص بشكل أكثر سرعة ودقة^[1].

مع التقدم التكنولوجي في المجال الصحي والانتقال إلى الأنظمة المؤتمتة، دخلت تقنيات الذكاء الصناعي والتعلم العميق مجال معالجة الإشارة مما جعل تحليل الإشارات القلبية وتشخيصها يتم بشكل أدق.

تم إجراء العديد من الدراسات والأبحاث ضمن مجال الذكاء الصناعي ومعالجة الإشارة خلال السنوات الماضية.

في عام 2019 تم نشر دراسة بعنوان «An Automated ECG beat classification system using convolutional neural networks»^[2].

استخدمت هذه الدراسة شبكة عصبية التقافية مقسمة إلى قسمين «Deep Auto-Encoders-DAE» و «Deep Neural Network» وتم استخدام قاعدة البيانات «MIT-BHI» والتي تحوي على 39000 عينة مقسمة إلى 7 أصناف، وقد أعطت الشبكة نتائج إيجابية بدقة وصلت إلى 99.73%.

في نفس السنة نشرت دراسة بعنوان

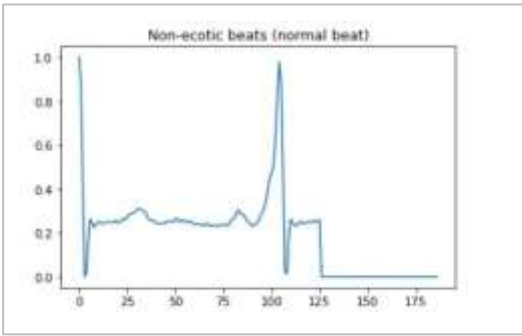
«Detection of Abnormal

Electrocardiogram (ECG) Using Wavelet Decomposition and Support Vector Machine (SVM)»^[3].

تم استخدام 36 عينة من قاعدة البيانات «MIT-BHI» و 36 عينة أخرى من قاعدة «PTB» تمت معالجة هذه العينات بواسطة تحويل ويفليت ومن ثم استخدمت

الضجيج الغوسي هو ضوضاء أو تشويش له دالة كثافة احتمالية مساوية لدالة الكثافة الاحتمالية للتوزيع الطبيعي [6]. يمكن التعبير عنه كما يلي:

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\sigma)^2}{2\sigma^2}}$$



الشكل (4) - توزيع العينات ضمن قاعدة البيانات.

بعد الانتهاء من هذه الخطوة نكون قد عالجتنا إشاراتنا بحيث تخلصنا من التحيز وأيضاً تجنبنا الوقوع في حالة الملائمة الزائدة أثناء التدريب.

2.2.2. بناء وتدريب الشبكة العصبية الالتفافية

تتضمن هذه المرحلة خطوتين وهما بناء الشبكة العصبية، ومن ثم تدريبها والحصول على النموذج النهائي للتصنيف.

قبل الدخول في تفاصيل شبكتنا العصبية يجب توضيح بعض المفاهيم الأساسية.


عملية التصنيف التي تقوم بها الشبكات العصبية الالتفافية تتم على عدة مراحل:

الأخرى فهي تمثل قيمة الإشارة في لحظة معينة، يبين الشكل (3) أحد الإشارات القلبية.

- توزيع البيانات بشكل متساوي

بعد استعراض البيانات لاحظنا أن 82% من البيانات هي ضمن الصنف الطبيعي الشكل (4)، وهذا أمر خاطئ لأنه يؤدي إلى انحياز الشبكة العصبية إلى تشخيص الصنف الطبيعي أكثر من باقي الأصناف.

الشكل (5) - الرسم البياني لتابع التنشيط ReLU.



الشكل (3) - إشارة قلبية طبيعية من قاعدة البيانات.

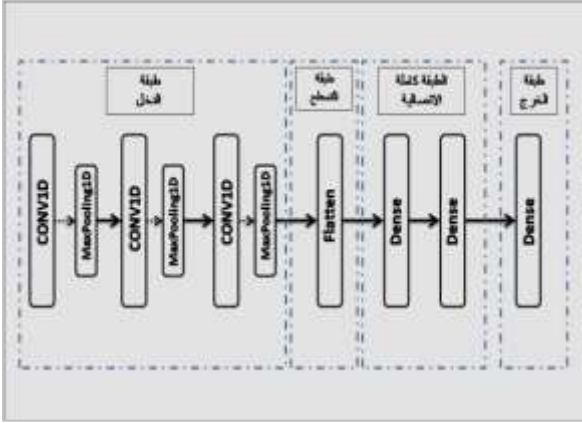
قمنا بأخذ 50000 عينة من الصنف الطبيعي وتعزيز عدد الأصناف الأخرى عن طريق إضافة إشارات تحتوي ضجيج حتى الوصول إلى 50000 عينة أيضاً، في نهاية هذه الخطوة نحصل على مجموع عينات 250000 موزعة على 5 أصناف بشكل متساوي.

- إضافة ضجيج إلى الإشارة

بما أن الإشارات ضمن قاعدة البيانات خالية من الضجيج ولزيادة قدرة الشبكة على تشخيص نقوم بإضافة الضجيج الغوسي إلى الإشارات.

$$S(y)_i = \frac{\exp(y_i)}{\sum_{i=1}^n \exp(y_i)}$$

يبين الشكل (6) هيكلية الشبكة العصبية التي قمنا ببنائها.



الشكل (6) - هيكلية الشبكة العصبية الالتفافية الخاصة

بنا.

تتكون الشبكة العصبية الالتفافية من 4 طبقات أساسية وهي: طبقة الدخل، طبقة التسطيح، الطبقة كاملة الاتصالية وطبقة الخرج.

تتكون الشبكة العصبية الالتفافية من 4 طبقات أساسية وهي: طبقة الدخل، طبقة التسطيح، الطبقة كاملة الاتصالية وطبقة الخرج.

- طبقة الدخل تحتوي طبقة الدخل على 3 طبقات التفافية أحادية البعد (Conv1D)، والتي تستخدم تابع التنشيط (ReLU) وكل طبقة متبوعة بطبقة تجميع (MaxPooling1D). الطبقات الالتفافية تحتوي كل واحدة على 64 فلتر، أبعاد كل فلتر هي 3*3.

- طبقة التسطيح

1- عملية استخلاص السمات والتي تتم ضمن الطبقات الالتفافية (Convolution Layers) وطبقات التجميع (Pooling Layers).

2- تحويل السمات المستخرجة إلى متجه أحادي البعد بواسطة طبقة التسطيح (Flatten)

3- معالجة المميزات بواسطة الطبقات كاملة الاتصالية (Dense)

4- إظهار الخرج على طبقة الخرج.

تابع التنشيط

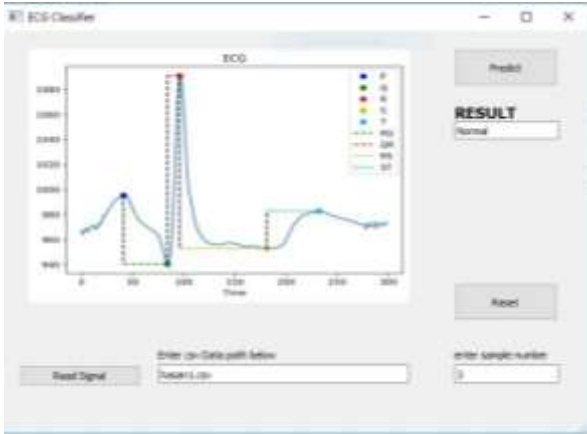
هي تابع تحدد فيما إذا كان العصبون يعمل أو لا، بمعنى هل يعطي خرج أو لا، وهي تعطي خرج في المجال بين 0 والـ 1.

تابع التنشيط (ReLU):

يعد هذا التابع من أكثر توابع التنشيط استخدامًا في الشبكات العصبية الالتفافية، وخاصة في الطبقات الالتفافية. كما نلاحظ في الشكل (5) فإن هذا التابع يحول أي قيمة مدخلة سالبة إلى قيمة معدومة، بينما في المجال $[0, +\infty]$ فالخرج أيضا ضمن المجال $[0, -\infty]$. [7]

تابع التنشيط (SoftMax)

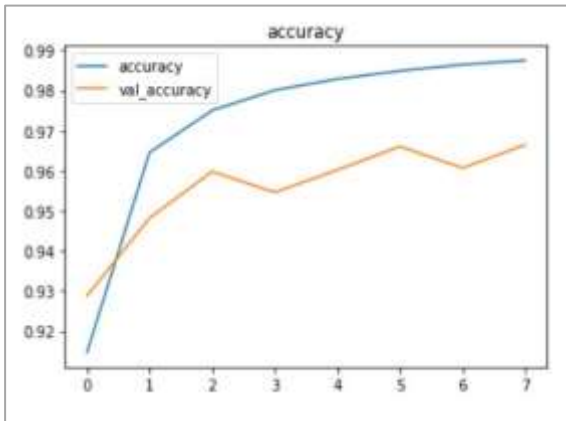
عادة ما يستخدم هذا التابع في طبقات الخرج في الحالات التي تحتوي أكثر من صنف. يقوم هذا التابع بتوزيع الاحتمالات بشكل متجه على جميع عصبونات الخرج، ويأخذ الأبطال الأكبر، ويكون الخرج في المجال $[0, 1]$.



الشكل (7) الواجهة التفاعلية الخاصة بالبرنامج.

3. تقييم النتائج

بعد الانتهاء من عملية التدريب والاختبار لابد من استعراض وتقييم النتائج التي حصلنا عليها من نموذجنا المقترح. حصلنا على دقة تصنيف 98.75% للتدريب و96.64% للاختبار الشكل (8). بينما نسبة الخطأ فهي 0.050 للتدريب و0.1425 للاختبار كما في الشكل (9).



الشكل(8)- دقة التدريب ودقة الاختبار التي وصل إليها لنموذج المقترح.

وهي الطبقة التي تقوم بتحويل المميزات المستخرجة من الطبقات السابقة بشكل متجه أحادي البعد.


- الطبقات كاملة الاتصالية
- تقوم هذه الطبقات بمعالجة السمات المستخرجة وتستخدم تابع التنشيط (ReLU)
- طبقة الخرج
- هي عبارة عن طبقة كاملة الاتصالية تحتوي على 5 عصبونات وتستخدم تابع التنشيط (SoftMax).

بعد بناء الشبكة العصبية الالتقافية نقوم بتقسيم البيانات إلى قسمين:

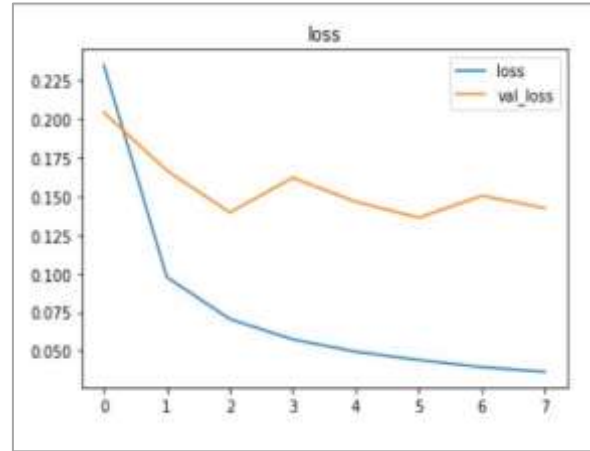
- بيانات التدريب وهي تشكل 70% من البيانات الكلية أي 175000 عينة.
- بيانات الاختبار وهي تشكل 25% من البيانات الكلية أي 62000 عينة.
- بيانات التحقق وتشكل 5% من البيانات الكلية أي 12500 عينة.

2.3. الواجهة التفاعلية

يبين الشكل (7) الواجهة التفاعلية التي قمنا ببنائها وكيف تظهر للمستخدم الإشارة القلبية والتصنيف الخاص بها.



الشكل (10) - مصفوفة الارتباك لنموذجنا المقترح.



الشكل (9) - قيمة الخطأ بالنسبة لبيانات التدريب وبيانات الاختبار.

3.1 مقارنة النتائج

يبين الجدول (1) مقارنة بين نموذجنا المقترح ودراسة المذكورة في الفقرة الأولى. تمت المقارنة على أساس الطريقة المتبعة، عدد العينات وأيضاً قيمة الدقة.

جدول (1) - مقارنة بين نموذجنا المقترح ونموذج Ullah.A^[4]

النموذج	الطريقة المتبعة	نوع الشبكة العصبية	عدد العينات	قيمة الدقة
نموذجنا المقترح	معالجة الإشارات بشكل مباشر وتدريب الشبكة عليها	شبكة عصبية التفاضلية أحادية البعد	200000 عينة موزعة على 4 أصناف	دقة النموذج وصلت إلى 96.64%
Ullah.A ^[4]	تحويل الإشارات إلى صور ثنائية البعد قبل التدريب	شبكة عصبية التفاضلية ثنائية البعد	لم تذكر الدراسة عدد العينات المستخدمة	دقة النموذج وصلت إلى 99.11%

كما يوضح الشكل (11) مصفوفة الارتباك الخاصة بالدراسة المقارن معها، نلاحظ ارتفاع الدقة لجميع الأصناف بسبب تحويل الإشارات إلى صورة واستخدام طبقات التفاضلية ثنائية البعد

NOR	99.4%	0.9%	0.2%	0.0%	0.3%	1.9%	7.1%	8.8%
	74853	63	17	3	26	47	32	11
PVC	0.2%	97.9%	0.1%	0.0%	0.0%	0.9%	0.2%	3.2%
	138	6958	6	0	0	23	1	4
PAB	0.0%	0.2%	99.1%	0.1%	0.3%	0.2%	0.7%	4.8%
	5	13	6963	9	23	6	3	6
RBB	0.1%	0.6%	0.4%	99.7%	0.4%	0.9%	2.0%	1.6%
	76	42	26	7046	36	23	9	2
LBB	0.1%	0.1%	0.1%	0.0%	98.8%	0.2%	0.0%	0.8%
	59	10	7	3	7991	4	0	1
APC	0.2%	0.2%	0.0%	0.1%	0.0%	95.8%	0.7%	3.2%
	123	12	2	7	1	2394	3	4
VFW	0.1%	0.1%	0.0%	0.0%	0.1%	0.0%	89.4%	0.0%
	48	7	2	0	10	1	404	0
VEB	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	77.6%
	3	3	2	0	1	0	0	97
	NOR	PVC	PAB	RBB	LBB	APC	VFW	VEB

الشكل (11) - مصفوفة الارتباك لنموذج دراسة Ullah.A^[4]

4. الخاتمة

اقترحنا في هذا البحث نموذج شبكة عصبية التفاضلية أحادية البعد «1D-CNN» لقراءة إشارات ECG وتشخيص أمراض القلب، يتميز النموذج المقترح بدقة عالية (96.64%) وخطأ قليل نسبياً (0.1425) قياساً بعدد البيانات الكبير الذي تم معالجته.

بالرغم من جميع الصعوبات الموجودة تمكنا من الحصول على نتائج مميزة ولن نقف عند هذا الحد بل سنسعى في قادم الأيام لتطوير وتحسين العمل عن طريق إيجاد وابتكار خوارزميات معالجة أخرى قد تكون أكثر فعالية ودقة.

المراجع

- 1- Benjamin, E.J.; Blaha, M.J.; Chiuve, S.E.; Cushman, M.; Das, S.R.; Deo, R.; de Ferranti, S.D.; Floyd, J.; Fornage, M.; Gillespie, C.; et al. 2017 Heart disease and stroke statistics update: A report from the American heart association. Circulation 2017, 135, 146–603.
- 2- Zubair, M.; Kim, J.; Yoon, C. An Automated ECG beat classification system using convolutional neural
- 3- Using Wavelet Decomposition and Support Vector Machine (SVM)." 2019 1st international Conference on Advances in science, Engineering and Robotics Technology (ICASERT) (2019):1-8. Deb, Pratik et al. "Detection of Abnormal Electrocardiogram (ECG) .
- 4- Ullah, A.; Anwar, M.S.; Bilal, M.; Majid, R.M. Classification of Arrhythmia by Using Deep Learning with 2-D ECG Spectral Image Representation. (2020).
- 5- www.kaggle.com/taejoongyoon/mitbit-arrhythmia-database
- 6- Philippe Cattin (2012-04-24). "Image Restoration: Introduction to Signal and Image Processing". MIAC, University of Basel.
- 7- www.towardScience.com