

دراسة مقارنة بين عائلات التحويل المويجي في الكشف الآلي عن الأمراض القلبية باستخدام إشارة ECG

طالبة الدراسات العليا: رشا قبيطري كلية الهندسة الكهربائية والالكترونية-جامعة حلب
إشراف الأستاذ الدكتور: ياسر استانبولي

المخلص:

إن أهم ما يميز هذه الإشارة عن باقي الإشارات الحيوية هي وجود المعقد QRS أو ما يعرف بالقمة R. تم في هذا البحث إيجاد القمة R باستخدام التحويل المويجي المتقطع ذو التداخل الأعظمي MODWT ودراسة تأثير نوع تابع التحويل المويجي في استخلاص الميزات من إشارة ECG وذلك ضمن المجال (الزمني_الترددية) حيث استخدمت كمداخل لشبكة عصبونية عميقة من النوع LSTM للتمييز بين 13 حالة قلبية. لقد تم تقييم أداء الشبكة من خلال الدقة والحساسية والنوعية، كانت قيمة هذه النسب على التوالي 95.55%، 94.73%، 100% عند استخدام الموجات (sym2, sym4,db2 ,coif5) في حين انخفضت هذه النسب عند استخدام كل من التابعين المويجيين (Fk4- haar) ، ويعود السبب في ذلك إلى أن شكل الموجة الأم للتابعين (Fk4- haar) مختلف عن شكل إشارة ECG.

الكلمات المفتاحية: إشارة التخطيط الكهربائي ECG(ElectroCardioGram) ،
التحويل المويجي المتقطع ذو التداخل الأعظمي Maximal Overlap Discrete
Wavelet Transform(MODWT)، شبكة الذاكرة (طويلة-قصيرة) المدى LSTM .

A Comparative study between wavelet families in automatic detection of heart diseases using ECG signal

Abstract

The most important characteristic of the ElectroCardioGram signal from the rest of biomedical signals is the presence of the complex QRS or R peak .In this research, this peak was found using Maximal Overlap Discrete Wavelet Transform MODWT and a study of the effect of the type transformation in extract features from ECG signal in the(time-frequency) domain was done. These features were used as inputs of deep neural network of type LSTM to classify 13 heart cases. The performance of this network was evaluated by accuracy, sensitivity, and specificity, and the value of these ratios were respectively 95,55%,94.73%,100%, when using (db2, sym2,sym4,haar) while these percentages were decreased when using both of the wavelet functions(coif5,fk4). The reason for this decreasing is wavelet function(coif5,fk4) differ in their shape from the ECG signal shape.

Key words: ElectroCardioGram(ECG), Maximal Overlap Discrete wavelet transform(MODWT), Long-Short Term Memory LSTM.

المقدمة

تعد الإشارات الحيوية أداة فعالة ومهمة تستخدم في العديد من الأغراض منها التشخيص وعمليات التحكم وأنظمة الترابط الدماغي الحاسوبي Brain-Computer Interface والتي تعرف باختصار BCI، إحدى هذه الإشارات هي إشارة التخطيط الكهربائي للقلب ECG [1].


إن إشارة التخطيط الكهربائي للقلب ElectroCardioGraph والتي تعرف باختصار ECG هي إحدى أهم الطرق المستخدمة في تشخيص أمراض القلب كونها تعبر عن النشاط الكهربائي لعضلة القلب الذي ينتج عن الانقباض والانقباض المتواتر لحجراته الأربع. فهي إشارات متغيرة مع الزمن تعكس الحالة الفيزيولوجية للقلب. يتم الحصول على هذه الإشارة بواسطة الكترودات تتوضع على سطح الجلد في أماكن محددة من الجسم فهي وسيلة آمنة لتشخيص أمراض القلب [1]. إن أهم ما يميز هذه الإشارة عن باقي الإشارات الحيوية هي وجود المعقد QRS أو ما يعرف بالقمة R. تمت العديد من الأبحاث في مجال الكشف عن القمة R كونها أهم قمة موجودة في إشارة ECG، حيث اقترح الباحث E.Pietka وزملاؤه خوارزمية لكشف المعقد QRS باستخدام مرشحات رقمية من النوع IIR والشبكات العصبونية الأمامية ذات التغذية العكسية وكانت دقة النتائج 90.45% [2]. قام الباحث P.Eillia بدراسة تأثير نوع عائلة التحويل الموجي في استحصال الميزات من إشارة ECG حيث قام بتطبيق التتابع الموجية (sym4,sym6,db4,db6) ولاحظ أن التتابع (sym4,db4) أعطت نتائج أفضل بلغت 93.95% في حين بلغت دقة النتائج عند استخدام التتابع (db6,sym6) 90.45% [3]. كشف الباحث Rekha Rani وزملاؤه المعقد QRS باستخدام التحويل الموجي المتقطع من النوع db4 من المستوى الرابع وكانت دقة النتائج 91.28% [4]. قام

الباحث Jose Anton Gutierrez-Gnecch وزملاؤه باستخدام التحويل المويجي المتقطع (Discret Wavelet Transform) DWT وكشف قمم إشارة ECG والفواصل الزمنية لها واعتبرها كميزات استخدمت كمدخل لشبكة عصبونية احتمالية لتصنيف 8 حالات قلبية وكانت دقة النتائج 92.74% [5]. استعرض الباحث Saumendra Kumar Mohapatra وزملاؤه مقارنة بين DWT وتحويل فورييه القصير زمنياً (Short –Time Fourier Transform) STFT في استخلاص الميزات من إشارة ECG للتمييز بين حالة طبيعية وحالة مرضية عامة، لقد تم التصنيف باستخدام المفسر متعدد الطبقات (Multi-Layer Perceptron) MLP وكانت دقة النتائج أعلى عند استخدام DWT حيث بلغت 76.7% في حين انخفضت الدقة إلى 50.7% عند استخدام STFT وهذا يدل على أن DWT أفضل [6]. اقترحت الباحثة Amani Hardan نموذجاً تكيفياً لمساعدة الأطباء على تصنيف الأمراض القلبية اعتماداً على شكل إشارة التخطيط الكهربائي ECG بالإضافة إلى ترشيحها وتخليصها من الضجيج. لقد قدمت نظام تكيفي جديد يعتمد على الأنظمة العصبية الضبابية التكيفية (ANFIS(Adaptive Neuro Fuzzy Interface System) الذي يدمج بين الشبكات العصبونية وطريقة الاستدلال الغامض، حيث استخدمت هذا النظام للاستفادة من إمكانيات الشبكات العصبونية التي تحكمها قواعد غامضة للحصول على نموذج تكيفي يقوم بتصنيف إشارات ECG إلى ثلاثة عشر مجموعة وفق قواعد منطقية محددة مسبقاً، ومن ثم ترشيح هذه الإشارات بشكل تكيفي تنبؤي بالاعتماد على قواعد منطقية للحصول على الإشارة الأصلية، وذلك عن طريق واجهة برمجية تم تصميمها باستخدام برنامج MATLAB وقد تم تنفيذ هذا النظام على شريحة FPGA. لقد كانت النتائج على النحو الآتي: الدقة 95.33%، الحساسية 94,82%، ومعدل خطأ 4.9% [7]. قام الباحث RUNNAN He وزملاؤه بالكشف الآلي عن تسعة أمراض من أمراض عدم الاتساق

القلبي باستخدام الشبكات العصبونية العميقة، حيث قام بالدمج بين شبكات الرواسب Residual Network والشبكات التكرارية من النوع شبكات الذاكرة الطويلة-قصيرة المدى ثنائية الاتجاه Bidirectional LSTM وكان F1 score للأمراض بشكل مجمل 0.806 [8].

هدف البحث

- تحليل إشارة التخطيط الكهريائي ECG باستخدام MODWT، وإيجاد القمم المميزة لإشارة ECG وهي (P-Q-R-S-T)، يبين الشكل (1) شكل إشارة ECG.



الشكل (1) شكل إشارة ECG.

- دراسة أثر عائلة MODWT في استخلاص الميزات من إشارة ECG وذلك ضمن المجال (الزمني_الترددي).

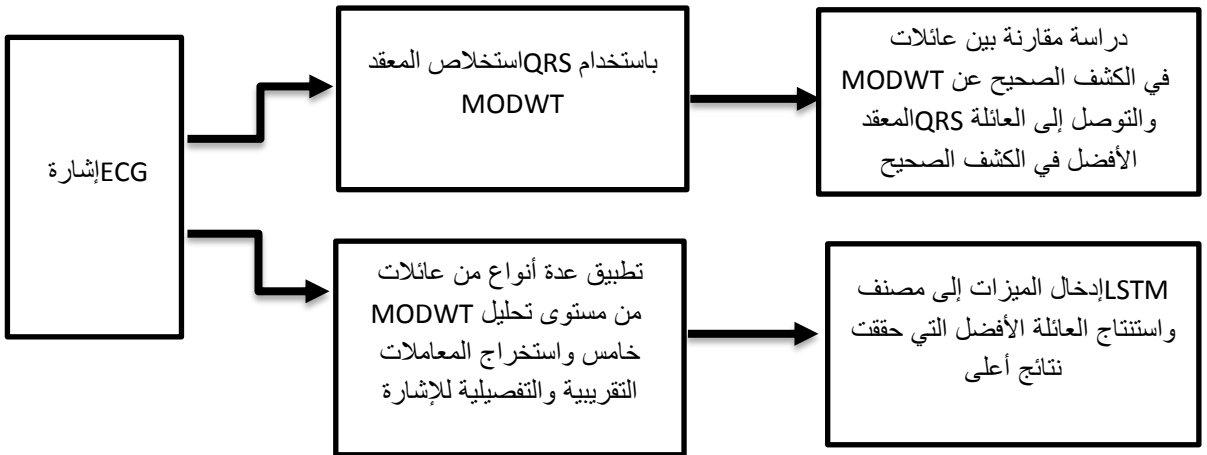
المواد وطرق البحث

1- مواد البحث

تم استخدام قاعدة بيانات MIT-BIH التي جمعت من تسجيلات حقيقية لإشارة ECG ، تم أخذ العينات من الإشارة بمعدل 360 عينة في الثانية ، كما تم استخدام برنامج MATLAB إصدار 2018 لبناء الخوارزميات في تنفيذ المعالجات وتحليل الإشارات، واستخدام حاسب بنظام تشغيل (Windows 7) ذو معالج Intel® core™ i7- (2670QM) ، سرعته (CPU 2.20 GHz)، وبذاكرة إظهار (819 MB) وذاكرة مؤقتة (RAM 8.00 GB).

2- الطرق المستخدمة في البحث

يبين الشكل (2) المخطط الصندوقي للبحث المنجز الذي تم وفق عدة مراحل سنقوم بشرحها لاحقاً.

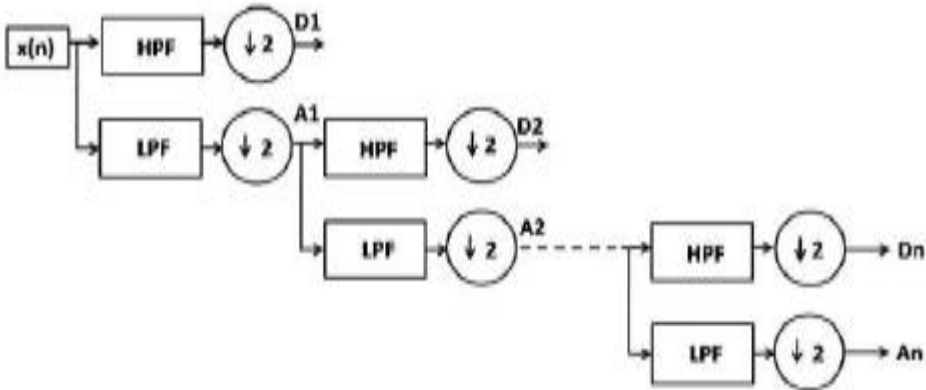


الشكل (2) المخطط الصندوقي للبحث

2-1- التحويل المويجي

إن تطبيق التحويل المويجي على إشارات ECG يكشف الخصائص التي تتعلق بطبيعة الإشارة في كل من المجال الزمني والتردد. يوجد نوعان من التحويل المويجي: الأول هو التحويل المويجي المستمر (CWT) والثاني التحويل المويجي المتقطع (DWT).

2-1-1- التحويل المويجي المتقطع (DWT) يقوم بتحليل الإشارة عند نطاقات تردد متعددة عن طريق استخدام banks filters الذي يقسم الإشارة إلى نطاقات فرعية. حيث تنقسم الإشارات إلى خصائص طيفية ذات تمرير عالي (Hi_D) وتمرير منخفض (Lo_D) [9] كما في الشكل (3).



الشكل (3) شجرة التحويل المويجي مبنية المعاملات التفصيلية والتقريبية [9]

2-1-2- التحويل المويجي المتقطع ذو التداخل الأعظمي: والمعروف اختصاراً بـ MODWT إن النظرية الأساسية MODWT قائمة على تطبيق الالتفاف الدائري مباشرة في المجال الزمني. يتم حساب معاملات مرشح الموجة (المعاملات التقريبية) ومعاملات

دراسة مقارنة بين عائلات التحويل المويجي في الكشف الآلي عن الأمراض القلبية باستخدام إشارة ECG

مرشح التقييس (المعاملات التفصيلية) عند مستوى معين z بأخذ تحويل فورييه المتقطع العكسي DFT الناتج عن مجموعة من DFTs جزئية [10].

سنبين فيما يلي ماهي نقاط التشابه والاختلاف بين التحويل DWT والتحويل MODWT وذلك ضمن الجدول (1).

الجدول (1) نقاط التشابه والاختلاف بين التحويل DWT والتحويل MODWT [10]


نقاط الاختلاف	نقاط التشابه
يستخدم MODWT قيم محذوفة حيث يحتفظ MODWT بـ $down$ sampled لكل مستوى من مستويات التحليل في حين أن ذلك غير موجود في DWT	كلاهما مرشحات خطية تعطي معاملات موجة ومعاملات تقييس.
MODWT مناسب لكل حجم العينات N في حين أن التحليل الكامل لـ DWT عند مستوى معين z يحتاج لأن يكون حجم العينات N مضروباً بـ 2^z (أي لا ضرب بقوة ولا قيود).	كلاهما يوفر تحليل متعدد الدقة MRA (Multi-Resolution Analysis) أساسه التدرج (التقييس)
إن القيم المشتقة من MODWT لا تتأثر بالانزياح الدائري لسلاسل الدخل الزمنية في حين أنها في DWT تكون معتمدة على نقطة البداية للسلاسل	كلاهما يوفر تحليل تباين العينة أساسه التقييس
إن التكرار أو الإسهاب (Highly Redundant) في MODWT يسهل اصطفاف معاملات الموجة والتقييس لكل مستوى مع سلاسل زمنية طبيعية كما أنه يزيد من الدرجات الفعلية للحرية EDOP لكل تقييس (تدرج) وينقص الاختلاف بين موجات محددة وهذا غير موجود في DWT	كلاهما طريقة هرمية لحساب التحويل بكفاءة

2-1-3- عائلات التحويل المويجي

تختلف عائلات التحويل المويجي عن بعضها البعض بشكل الموجة الأم، سنورد فيما يلي الجدول (2) الذي يوضح الاختصار لكل عائلة [10]، يبين الشكل (4) مجموعة من عائلات التحويل المويجي .

الجدول (2) عدة عائلات من الموجات مع اختصارها

Names of the wavelet families	Abbreviation
Haar wavelet	haar
Daubechies wavelets	Db
Symlets	Sym
Coiflets	Coif
Fejer-Korovkin	FK




الشكل (4) مجموعة من عائلات MODWT [10]

2-2- إيجاد القمم في إشارة ECG باستخدام التحويل MODWT:

2-2-1- إيجاد القمة R:

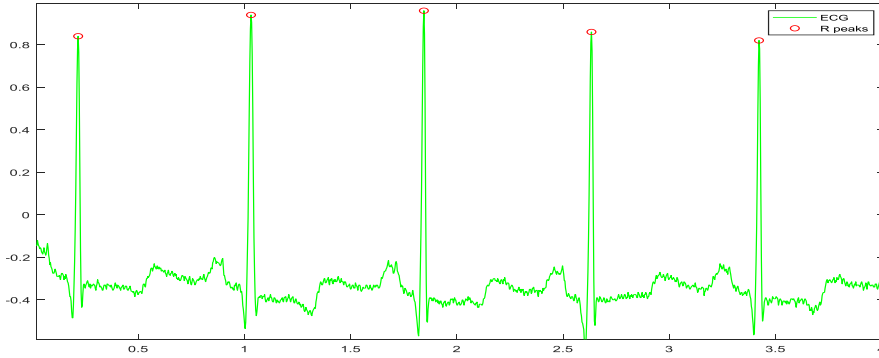
- نقوم بتطبيق التحويل MODWT من الدرجة الخامسة باستخدام التابع sym4.

- نقوم بإعادة تشكيل الإشارة من المستوى الخامس باستخدام التحويل المويجي المتقطع ذو التداخل الأعظمي العكسي IMODWT باستخدام التابع sym4، مما يجعل القمم أكثر وضوحاً بعدها بسبب تخامد القمم الأصغر كما هو موضح في الشكل (5) الذي يظهر إشارة ECG معاد تشكيلها من المستوى الخامس باستخدام التحويل IMODWT من النوع sym4.



الشكل (5) إشارة ECG معاد تشكيلها من المستوى الخامس باستخدام التحويل IMODWT من النوع sym4


- نقسم الإشارة الناتجة بعد تطبيق التحويل المويجي إلى مجالات ونكشف القمة الأعلى الموجودة في كل مجال على حدة كما هو موضح في الشكل (6) الذي يظهر إشارة ECG والقمم R المكتشفة.



الشكل (6) إشارة ECG والقمم R المكتشفة

2-2-2- إيجاد القمة S:


القمة S هي الذروة السفلى التي تقع مباشرة بعد القمة R، لإيجادها يتم تحديد المجال الصغير الذي يبدأ بالقمة R وينتهي بالقمة T ونوجد القمة S على اعتبارها تمثل أدنى قمة ضمن هذا المجال كما هو موضح في الشكل (7) الذي يظهر إشارة ECG والقمم S المكتشفة.



الشكل (7) إشارة ECG والقمم S المكتشفة

3-2-2- إيجاد القمة Q:

القمة Q هي الذروة السفلى التي تقع مباشرة قبل القمة R، لإيجادها يتم تحديد المجال الصغير الذي يبدأ بالقمة P وينتهي بالقمة R ونوجد القمة Q على اعتبارها تمثل أدنى قمة ضمن هذا المجال كما هو موضح في الشكل (8) الذي يظهر إشارة ECG والقمة Q المكتشفة.



الشكل (8) إشارة ECG والقمة Q المكتشفة

4-2-2- إيجاد زمن ظهور القمتين P و T:

تم إيجاد زمن ظهور القمتين P و T بطريقتين مختلفتين إلا أن الطريقة الثانية كانت فعالة أكثر بشكل عام وتم استخدامها في هذا البحث.

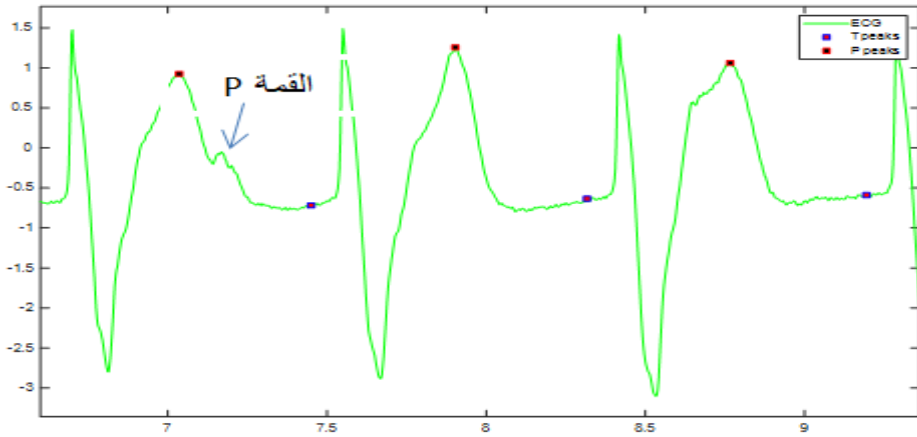
الطريقة الأولى:

- ❖ يتم تحديد المجال الواقع بين كل من القمة S في أول الدور من الإشارة والقمة Q في الدور التالي للدور السابق لهذه الإشارة.
- ❖ نحدد موقع القمة الأعلى ضمن المجال السابق.
- ❖ نحدد نوع القمة السابقة فيما إذا كانت P أو T. يوجد قمتين في المجال بين R و Q هما P و T، في الحالة الطبيعية القمة P أعلى ولكن في بعض الأمراض يكون T أعلى مما

يؤدي إلى أخطاء برمجية. لتفادي هذا الخطأ يجب التمييز بين القمتين من خلال تحديد القمة التي تأتي أولاً والتي تكون أقرب للقمة Q في الدور التالي.

❖ نحدد القمة الأخرى.

تحدث الأخطاء عندما تتوضع كل من القمتين T و P في موضعين متقاربتين في المجال الواقع بين القمة S في أول الدور من الإشارة والقمة Q في الدور التالي للدور السابق لهذه الإشارة كما هو موضح في الشكل (9) الذي يظهر إشارة ECG والقمتين T و P حيث حدث خطأ نتيجة تموضع كل من القمتين T و P في موضعين متقاربتين .



الشكل (9) إشارة ECG والقمتين T و P حيث حدث خطأ نتيجة تموضع كل من القمتين T و P في موضعين متقاربتين


الطريقة الثانية:

- ✓ يتم تحديد المجال الواقع بين كل من القمة S في أول الدور من الإشارة والقمة Q في الدور التالي للدور السابق لهذه الإشارة.
- ✓ نقوم بتطبيق التحويل MODWT من الدرجة الخامسة ونقوم بإعادة تشكيل الإشارة للمستوى الخامس باستخدام التحويل العكسي IMODWT مما يجعل القمم أكثر وضوحاً بسبب تخامد القمم الأصغر.


- ✓ نزح الإشارة إلى المستوى الصفري.
- ✓ نقسم الإشارة الناتجة بعد تطبيق التحويل المويجي إلى مجالين ونكشف القمة الأعلى الموجودة في كل مجال.

3-2- الفترة:

لا يمكن استخراج القمم P و T بالطرق التقليدية نتيجة وجود ضجيج أدى إلى وجود قمتين متتاليتين. لذلك قمنا بالترشيح باستخدام المرشح **Savitzky-Golay** من أجل إزالة الضجيج كما نلاحظ في الشكل (10) الذي يظهر إشارة ECG بوجود الضجيج وإشارة ECG مرشحة.



A



B

الشكل (10) (A): إشارة ECG بوجود الضجيج، (B): إشارة ECG مرشحة

2-4- تأثير نوع تابع الموجي في استخلاص الميزات:


سنقوم بدراسة نوع تابع التحويل الموجي في استخلاص الميزات من إشارة ECG وذلك ضمن المجال (الزمني_الترددية)، حيث قمنا بداية بتطبيق التحويل MODWT ومن المستوى الخامس باستخدام مجموعة متنوعة من توابع التحويل الموجي ومن ثم تم استخراج المعاملات التقريبية (A1,A2,A3,A4,A5) والمعاملات التفصيلية (D1,D2,D3,D4,D5)، بعدها تم تطبيق التحليل الإحصائي على مجموعة من هذه المعاملات وبذلك حصلنا على مجموعة ميزات استخدمت مداخل لشبكة عصبونية عميقة للتصنيف بين 13 حالة قلبية. لقد تم استخدام المعاملات (D3-D4-A5) فقط كون المجال الترددي لبقية المعاملات هوي ولا تظهر فيه القمة R بشكل واضح. يبين الجدول (3) مميزات إشارة ECG المستخرجة من المعاملات السابقة.

الجدول (3) مميزات إشارة ECG المستخرجة من المعاملات (D3-D4-A5)

التباين لمعامل التفاصيل (Var D4)D3	الانحراف المعياري لمعامل التقريب (STD A5)A5
الانحراف المعياري لمعامل التفاصيل (STD D4)D4	القيمة متوسطة لمعامل التقريب (Mean A5)A5
القيمة المتوسطة لمعامل التفاصيل (Mean D4)D4	الانحراف المعياري لمعامل التفاصيل (STD D3)D3
التباين لمعامل التفاصيل (Var D4)D4	القيمة متوسطة لمعامل التفاصيل (Mean D3)D3

2-5- مقارنة بين عدة أنواع من عائلات MODWT في تصنيف الأمراض القلبية:

لقد تم استخدام المميزات السابقة لعدة أنواع من عائلات من عائلات التحويل الموجي كمدخل لشبكة عصبونية عميقة من النوع LSTM كما هو موضح في الشكل (11).



الشكل (11) تطبيق عدة أنواع من عائلات التحويل المويجي لاستحصال الميزات واختبارها عبر المصنف LSTM

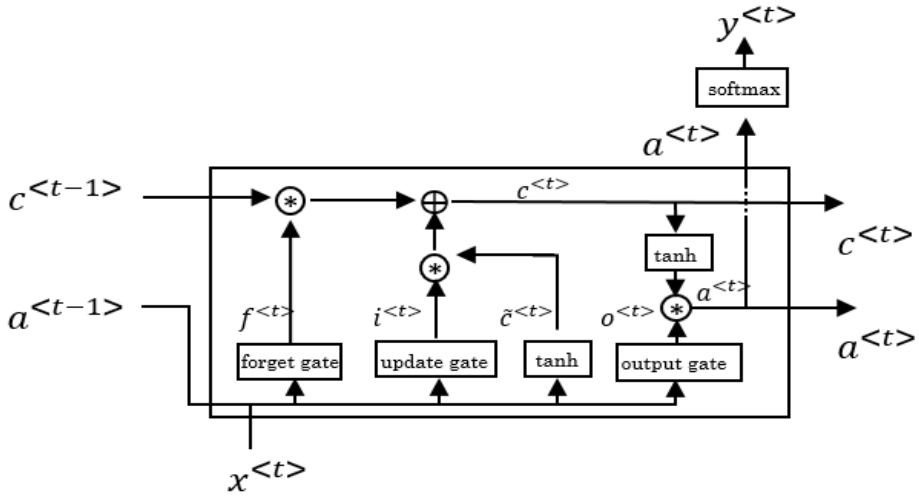
2-6- التصنيف باستخدام الشبكات العصبونية العميقة ذات الذاكرة (طويلة-قصيرة) المدى LSTM:

قدمت الشبكات ذات الذاكرة طويلة-قصيرة المدى حلاً لمشكلة اختفاء التدرج، وسنقوم بشرح مبسط للبنية الداخلية لهذا التصميم من الشبكات العصبونية وتحديد كيفية حل مشكلة اختفاء التدرج. تستخدم الذاكرة طويلة المدى (LSTM) أربعة بوابات تؤدي كل منها وظيفة محددة [11] وهذه البوابات هي:

- ✓ بوابة الإدخال / التحديث (Γ_u) تتحكم فيما يجب كتابته إلى خلية LSTM.
- ✓ بوابة النسيان (Γ_f): تتحكم فيما إذا كان يجب محو الخلية.
- ✓ بوابة الإخراج (Γ_o): تتحكم بمقدار ما يجب كشفه أو إخرجه من الخلية.
- ✓ تتحكم البوابة الرابعة (g) في مقدار الكتابة إلى الخلية.

يمكن أن يتم استذكار أو نسيان الحالة السابقة لحالة الخلية الداخلية، ويمكن إما زيادة أو تقليل كل عنصر من عناصر حالة الخلية هذه بمقدار واحد في كل خطوة زمنية. يمكن تمثيل حالات الخلايا هذه على أنها عدادات قيمتها تأخذ القيم من -1 إلى 1 في كل

خطوة زمنية. تتمثل الخطوة الأولى ل LSTM في تحديد المعلومات التي سيتم إزالتها من حالة الخلية الداخلية. يتم اتخاذ هذا القرار من قبل طبقة Sigmoid تسمى (طبقة بوابة نسيان). تنظر إلى a_{t-1} و x_t ، وتخرج رقم بين 0 و 1 لكل رقم في وحدة الذاكرة السابقة c_{t-1} . يمثل الرقم في وحدة الذاكرة السابقة، 1 يعني الاحتفاظ بهذا الرقم بالكامل بينما يمثل 0 التخلص من هذا الرقم بالكامل. يبين الشكل (12) البنية الداخلية للشبكات العصبونية ذات الذاكرة (طويلة-قصيرة) المدى LSTM



الشكل (12) البنية الداخلية للشبكات العصبونية ذات الذاكرة (طويلة-قصيرة) المدى LSTM [11]

لقد تم تدريب الشبكة المصممة في هذا البحث بـ 83 عينة واختبارها بـ 35 عينة. يقوم المصنف بتمييز 13 صنف (12 حالة مرضية والحالة الطبيعية).

يبين الشكل (13) تحليل الشبكة LSTM باستخدام MATLAB حيث تتكون من الطبقات

الآتية:

☒ طبقة دخل تسلسلية واحدة Sequence Input Layer.


دراسة مقارنة بين عائلات التحويل المويجي في الكشف الآلي عن الأمراض القلبية باستخدام إشارة ECG

طبعة ذاكرة قصيرة وطويلة الامد Bilstm Layer مزودة 400 وحدة مخفية Hidden Units.

طبعة اتصال كامل Fully Connected Layer وتقوم بضرب الدخل بمصفوفة الأوزان ومن ثم تضيف الناتج لشعاع الانزياح.

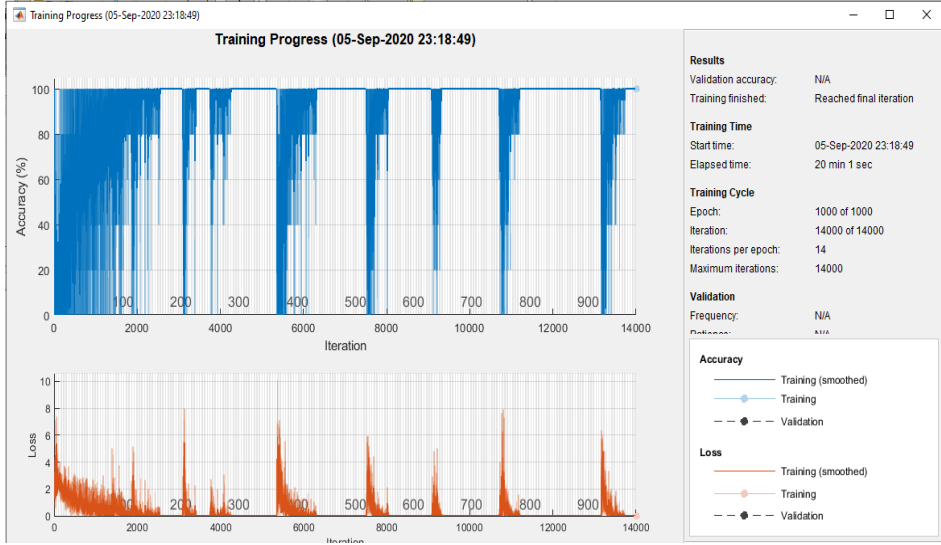
طبعة التنعيم SoftMax Layer: تقوم بتطبيق تابع التنعيم الأعظمي SoftMax على الدخل.

طبعة خرج مصنفة Classification Layer.



الشكل (13) تحليل الشبكة المستخدمة LSTM باستخدام برنامج MATLAB

يبين الشكل (14) عملية تدريب الشبكة LSTM باستخدام برنامج MATLAB، حيث بلغ عدد دورات التدريب epoch (1000) مرة.



الشكل (14) عملية تدريب الشبكة LSTM باستخدام MATLAB

7-2- تقييم أداء الشبكة:

تمّ تقييم أداء الشبكة العصبونية من خلال الدقة (Accuracy) والحساسية (Sensitivity) والنوعية (Specificity) تعطى هذه المعايير بالعلاقات التالية:

$$\text{ACCURACY} = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \times 100\% \quad (1)$$

$$\text{SENEITIVITY} = \frac{T_p}{T_p + F_n} \times 100\% \quad (2)$$

$$\text{SPECIFICITY} = \frac{T_n}{T_n + F_p} \times 100\% \quad (3)$$

حيث أن:

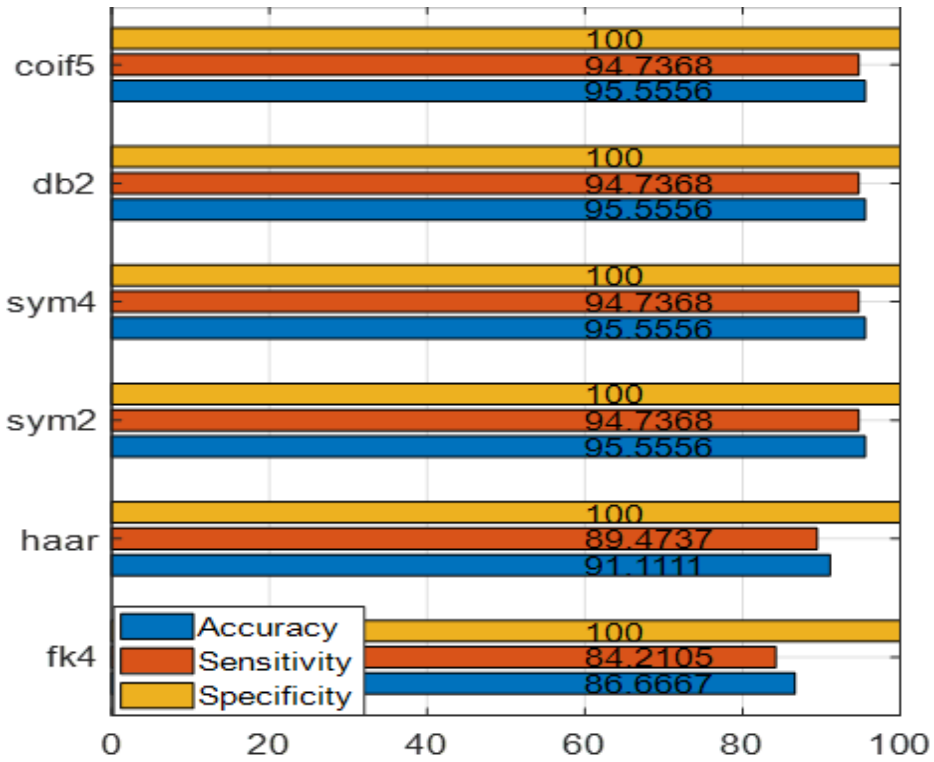
T_p : حالة مرضية وتمّ تشخيصها بشكل صحيح.

T_n : حالة سليمة وتمّ تشخيصها بشكل صحيح.

F_p : حالة سليمة وتمّ تشخيصها على أنها مرضية.


F_n : حالة مرضية وتمّ تشخيصها على أنها سليمة.

يظهر الشكل (15) تقييم لأداء المصنف من خلال الدقة والحساسية والنوعية من أجل توابع موجية مختلفة أستخدمت لاستنتاج مميزات إشارة ECG في المجال الزمني_الترددي عند المستوى الخامس.




الشكل (15) الدقة والحساسية والنوعية للمصنف من أجل توابع موجية مختلفة

نلاحظ من الشكل (15) أنه عند استخدام التتابع (sym2- sym4 -db2 -coif5) كانت دقة المصنف وحساسيته ونوعيته الأعلى حيث كانت النسب على التوالي 95.55%, 94.73%, 100% في حين انخفضت دقة المصنف وحساسيته عند استخدام كل من التابعين الموجبيين (Fk4- haar)، ويعود السبب في ذلك إلى أن التتابع الموجبية (sym2- sym4 -db2 -coif5) ذات أشكال قريبة من شكل إشارة ECG مما يجعلها قادرة على تحديد مميزات دقيقة في هذه الإشارة بالمقارنة مع التابعين الموجبيين (Fk4- haar) الذين يختلفان في شكلهما عن إشارة ECG، يبين الشكل (16) شكل التابع الموجبي haar كما يبين الشكل (17) شكل التابع الموجبي Fk4



الشكل (16) شكل التابع الموجبي haar



الشكل (17) شكل التابع الموجبي Fk4

النتائج ومناقشتها

- إمكانية تحليل إشارة ECG باستخدام التحويل MODWT وإيجاد القمة R بشكل آلي.
- تم دراسة تأثير نوع تابع التحويل MODWT في كشف القمة R بشكل صحيح من خلال استخدام عدة أنواع من عائلات MODWT وهي (sym2- sym4 haar -Fk4 -coif5 -db2) وقد تم التوصل إلى أن النوع sym4 هو أفضل الأنواع في كشف القمة R.
- تم دراسة تأثير نوع تابع MODWT في استخلاص الميزات من إشارة ECG وذلك ضمن المجال الزمني-الترددي حيث استخدمت هذه الميزات كمدخل لشبكة عصبونية عميقة من النوع LSTM للتمييز بين 13 حالة قلبية وقد تبين من خلال الدراسة أن التتابع (sym2- sym4 -db2 -coif5) كانت دقة المصنف وحساسيته ونوعيته الأعلى عند استخدامها في حين انخفضت الدقة والحساسية عند استخدام كلا من التابعين (Fk4- haar) ويعود السبب في ذلك إلى أن التتابع (sym2- sym4 -db2 -coif5) ذات أشكال قريبة من شكل إشارة ECG مما يجعلها قادرة على تحديد ميزات دقيقة بالمقارنة مع التابعين (Fk4- haar) اللذان يختلفان في شكلهما عن شكل إشارة ECG.

الاستنتاجات والتوصيات

تم إجراء العديد من الأبحاث للكشف الآلي عن قمم إشارة ECG ولا سيما القمة R أو ما يعرف بالمعقد QRS الذي يعتبر من أهم ما يميز شكل إشارة ECG عن باقي الإشارات الحيوية. تم في هذا البحث تقديم طريقة فعالة للكشف عن القمة R وباقي القمم بالاعتماد على التحويل MODWT تم الاستفادة منها في التمييز بين 13 حالة قلبية باستخدام

الشبكات العصبونية العميقة LSTM وقد تم مقارنة بحثنا مع الأبحاث السابقة وفق الجدول (4).

الجدول (4) مقارنة بين بحثنا والأبحاث السابقة في مجال تصنيف الأمراض القلبية

البحث	الدقة	الحساسية	النوعية
[5],2016	92.74%	-	-
[6],2018	76.7%	-	-
[7],2021	95.33%	-	-
بحثنا	95.55%	94.73%	100%

- [1] George J Taylor, "**150 Practice ECGs Interpretation and Review**", third edition, Blackwell Publishing, USA, 2006.
- [2] Kiani F., Maghsoudi K., "**Classification of from ECG using Neural Net**", Iran, 2016.
- [3] Wenbo Z., "**Detection Features from ECG signal using Discret Wavelet Transformation** ", China, 2012.
- [4] Siva A., Siddhard S., "**Classification of Heart Disease using Wavelet Transformation and Neural Network Model**", 2018, India.
- [5] Gutierrez J., 2016–**DSP–based arrhythmia classification using using wavelet transform and probabilistic neural network**, Biomedical Signal Processing Signal Processing and Control, 34(2016), 44–56.
- [6] Saumendra K., 2018–**Detection of Arrhythmia using Neural Network**, Proceedings of the first International Conference on Information Technology and Knowledge Management, 1(14), 97–100.

- [7] Hardan A.–**Designing and Constructing an Intelligent Adaptive Filter for Medical Signal Processing Using FPGA technology**,2021, Project prepared to obtain PHD degree in Programmable Elecotronic systems, Aleepo University.
- [8] Runnan H., Yangl L.,"**Automatic Cardiac Arrythmia Classification using Combination of Deep Residual Network and Bidirection LSTM**",China,2019.
- [9] Rubi B., "**Wavelet Transformation Theory**", India,2005.
- [10] Charles R–Maximal Overlap Wavelet Statistical Analysis with Application to Atmospheric Turbulence, Applied Physical Laboratory, USA,2005.
- [11] Kuan F.," **Long –Short Term Memory Neural Network and its Application**", China,2018.

