

مصنّف جديد لكشف مرض عدم انتظام ضربات القلب مبني على الاستدلال العائم بالشبكات العصبونية

الدكتورة رشا مسعود*

محمد الرفاعي**

(تاريخ الإيداع 24 / 4 / 2017. قُبل للنشر في 24 / 5 / 2017)

□ ملخص □

تم في هذا البحث التوصل إلى بناء مصنّف جديد لكشف مرض عدم انتظام القلب Cardiac Arrhythmias على اقتباس إشارة ضربات القلب ECG ، حيث يمكن للمصنّف كشف مواقع ضربات القلب ضمن الإشارة ECG واستخلاص السمات الخاصة بها وباستخدام هذه السمات يتم اتخاذ القرار بنوع ضربة القلب التي تم كشفها فيما لو كانت معتلة (مريضة) أم طبيعية. ركّز البحث على كشف المرضين 1- خوارج الانقباض البطيني PVC و 2- خوارج الانقباض الأذيني PAC. استطاع المصنّف الجديد كشف المرضين بسبة عالية حيث بلغ وسطي دقة الكشف 97.56%. تم تطوير المصنّف جديد بناءً على خوارزميات الاستدلال العائم باستخدام الشبكات العصبونية ANFIS، حيث يحتوي على شبكتين عصبونيتين متعاقبتين، تقوم الشبكة الأولى بفرز ضربات القلب الطبيعية من المعتلة في حين تقوم الشبكة الثانية بكشف نوع المرض في الضربات المعتلة فقط. لقد أمّنت هذه البنية الجديدة فعالية ودقة كشف أعلى مقارنةً بالمصنّفات المعروفة عالمياً.

الكلمات المفتاحية: ECG : إشارة القلب الكهربية، PVC : انقباض بطيني سابق لأوانه ، PAC : انقباض أذيني سابق لأوانه، NB : نبضة طبيعية، ANFIS : نظام استدلال عصبي عائم متكيف

* أستاذ مساعد - قسم الهندسة الطبية - كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق - سورية.
** طالب دراسات عليا (ماجستير) - قسم الهندسة الطبية - كلية الهندسة الميكانيكية والكهربائية - جامعة دمشق - سورية.

New Classifier for Cardiac Arrhythmias Recognition Based on Fuzzy-Neural Networks

Dr. Rash Masood*
Mohammad AL-refae**

(Received 24 / 4 / 2017. Accepted 24 / 5 / 2017)

□ ABSTRACT □

It is found in this research to adopt a new classifier for diagnosing Cardiac Arrhythmias depending on detecting the Electrocardiograph (ECG), where the classifier can identify heart beats and extract its features. Using these features we can decide if the heart beat is healthy or disordered.

Beside detection normal heart beats, the research focused on detection two diseases:

1. Premature Ventricular Contraction PVC.
2. Premature Atrial Contraction PAC.

The new classifier diagnosed the two diseases with a very high quality where the accuracy average is 97.56%.

The new classifier is developed depending on algorithms of ANFIS Adaptive Neural Fuzzy Inference System. System includes two consecutive neural networks; first one sorts the heart beats to two types: normal and abnormal were the second diagnose the disease of the disordered heartbeats only.

This new classifier offered higher levels of efficiency and accuracy in the comparison with the internationally known classifiers.

Keywords: (ECG) Electrocardiograph, (NB) Normal Beat, (PVC) Premature ventricular Contraction, (PAC) Premature Atrial Contraction, (ANFIS) Adaptive Neuro Fuzzy Inference System.


* Associate Professor- Faculty Mechanical and Electrical- -Damascus University –Syria.

**Postgraduate Student, Faculty Mechanical and Electrical- -Damascus University –Syria

مقدمة

تعد إشارة القلب الكهربية (ECG) ElectroCardioGram من أهم الإشارات الحيوية المقتبسة من جسم الإنسان، حيث أنها الإشارة التشخيصية الأساسية التي يعتمد عليها الأطباء - بغالبية اختصاصاتهم - في التشخيص الأولي وأحياناً النهائي لشريحة واسعة من الأمراض [1][9]. حيث يرسم مخطط القلب الكهربائي حالة القلب الكهربية من استقطاب وزوال استقطاب لأجزاء القلب في كل ضربة من ضربات القلب، والتي بدورها تعكس طبيعة عمل القلب أثناء هذه الضربة.

تتغير إشارة القلب الكهربية (ECG) في العديد من أمراض القلب أو عند حدوث خلل في أحد الأعضاء أو الأنظمة الأخرى في جسم الإنسان يؤدي إلى تغير في كهربية القلب. مما يجعل الطبيب يلاحظ هذا التغير ويقوم بالاشتباه بأمراض معينة، أو حتى في بعض الأحيان يقوم بتشخيص هذا المرض اعتماداً على الإشارة المقتبسة [1][9]. يبين الشكل (1) شكل إشارة ضربة القلب الطبيعية [1]، موضحاً عليها المراحل الأساسية التي تمر بها، حيث تتكون ضربة القلب الطبيعية من موجة P، مركب QRS وموجة T وموجة U صغيرة مرئية عادةً في 50 إلى 75% من رسم القلب.




الشكل (1): إشارة القلب الكهربية في الحالة الطبيعية بمكوناتها وتقسيماتها من وجهة نظر طبية [1].

يتغير شكل ضربة القلب عند المرضى المصابين بمرض عدم انتظام ضربات القلب، حيث تتخلل تلك الضربات غير السليمة بين الضربات الطبيعية؛ ويتم كشف هذا المرض من خلال مراقبة إشارة الـ ECG لفترة من الزمن تتراوح من عدة دقائق إلى عدة ساعات، فمن شكل الضربة يمكن تحديد نوع مرض عدم انتظام ضربات القلب، أو اكتشاف أمراض أخرى [1][9].

سيتم في هذه المقالة التركيز على كشف النوعين الأكثر شيوعاً لضربات القلب المعتلة بالإضافة إلى الضربة

الطبيعية، كما هو موضح في الشكل (2) :

1. خوارج الانقباض البطيني (Premature Ventricular Contraction) .PVC.
2. خوارج الانقباض الأذيني (Premature Atrial Contraction) .APC.
3. الضربة الطبيعية (Normal Beat) NB.



الشكل (2): إشارات الـ PVC و NB التي تم تصنيفها بواسطة دراسة المرجع [17].

قام الباحث BENALI R وزملاؤه في العام 2009 بتطبيق نظام استدلال عائم باستخدام الشبكة العصبونية (ANFIS) خاص بتصنيف الإشارة الكهربائية للقلب [16]، حيث قاموا باختبار النظام على مجموعة إشارات حقيقية مسجلة ومرقمنة موجودة على قاعدة البيانات المفتوحة [18]. حيث وفرت قاعدة البيانات - المعتمدة عالمياً - تسجيلات مستمرة لإشارة القلب الكهربائية تحوي أعداداً كبيرة من الضربات القلبية، كما وفرت قاعدة البيانات معلومات عن كل ضربة قلبية فيما إن كانت سليمة أو مريضة مرضاً معيناً، مما مكن الباحثين من تقييم عملهم، وحصلوا على تصنيف صحيح بدقة %95.91.

كما قام الباحث Szczepa A وزملاؤه في عام 2010 باستخراج خصائص ومحددات كل ضربة قلبية بعد المعالجة الأولية لإشارة القلب الكهربائية، واستعانوا بخوارزميات رياضية لم تُستخدم سابقاً في هذا المجال. اعتمدت هذه الخوارزميات في تحليل الإشارة واستخراج بارامتراتنا على طرق رياضية تقليدية من حساب قيم عظمى ودنيا، ووضع عتبات لاكتشاف وتحديد نقط الإشارة الأساسية، وغيرها من عمليات إحصائية، واستطاعوا الحصول على خصائص كل ضربة ومحدداتها الزمنية (مدة كل قسم من الإشارة)، وعلى الخصائص التي تعبر عن شكل الإشارة من مطالات وميول للإشارة، ولكن اقتصرت عمليات معالجة الإشارة عندهم على المجال الزمني، ولم يتطرقوا للمعالجة في المجال الترددي [13]. أيضاً لم تتطرق الدراسة إلى تصنيف الإشارات وإنما اكتفت باستخراج سبع سمات فقط لخصائص الإشارة التي هي عبارة عن بارامترات من مطالات وميول وفترات زمنية تم استخراجها بطرق رياضية وإحصائية تقليدية تعتمد على التعتيب وعلى المعالجة في المجال الزمني مأخوذة من دراسة سابقة [12].

قام الباحثان Sanavullah M و Sumathi S في عام 2010 باستخراج خصائص وسمات إشارة القلب اعتماداً على تحويل المويجات wavelet، وتميزت هذه الدراسة عن سابقتها بمعالجة الإشارة في المجال الترددي، والتي ساعدت في استخراج السمات الشكلية للإشارة بشكل أكثر دقة. ثم طبق الباحثان نظام ANFIS على المحددات والخصائص المستنتجة بهدف تصنيف الإشارة [4]. حصل الباحثان على نتائج بدقة إجمالية %94.25، حيث قارنا نتائجنا بقرارات أطباء مختصين حول كل ضربة قلبية [4].

في العام 2011 قام الباحث Romano H ومجموعة من الباحثين في جامعة San Juhan الوطنية بتطوير خوارزميات لتصنيف حالات مرضية اعتماداً على إشارة ECG [7]، حيث تم تحديد الحالات الثلاثة السابقة لضربة

القلب (PVC, PAC, NB). تم الحصول على نتائج ذات بدقة وسطية 95.5%، حيث قارنوا نتائجهم بقرارات أطباء مختصين حول كل ضربة قلبية، يظهر الشكل (2) أشكال الإشارات الثلاث التي تم تصنيفها، حيث اعتمدوا نظام ANFIS في بحثهم واستخرجوا خصائص الإشارة بطرق هجينة (معالجة في المجال الزمني ومعالجة في المجال الترددي).

أهمية البحث وأهدافه:

الهدف من هذا البحث هو تصميم نظام محوسب لتحليل وتفسير إشارة القلب الكهربائية (ECG)، حيث يقوم هذا النظام باستخراج خصائص ومحددات الإشارة التي تفيد في التشخيص، ومن ثم تصنيف هذه الإشارة وتحديد إن كانت الإشارة سليمة أو مريضة مرضاً معيناً بناءً على هذه الخصائص والمحددات. سيكون هذا النظام قادراً على التعامل مع مختلف إشارات القلب، من أشخاص مختلفين أي أنه يتكيف لاستخلاص وتصنيف إشارات القلب لأشخاص مختلفين. يهدف البحث إلى بناء نظام قادر على تحليل وتصنيف كل نبضة من نبضات القلب بالزمن الحقيقي، وهذا يجعل النظام مفيداً جداً في حالات المراقبة المستمرة لعمل القلب، وخصوصاً في أقسام العناية المشددة في المشافي أو للأخصائيين الذين يستخدمون أنظمة مراقبة عن بعد لحالة مرضاهم، حيث يتم تصنيف إشارة القلب مباشرةً وتحديد نوع النبضة وبالتالي إخطار الكادر المسؤول عن مراقبة المريض باتخاذ الخطوات المناسبة لحل المشكلة. كما أن كثرة الحالات والتشوهات التي تجري على المخطط الكهربائي للقلب تجعل الإلمام بها جميعاً أمراً صعباً، لذلك يسهم البحث في مساعدة الكوادر الطبية التي تفتقد الخبرة على معرفة الحالة المرضية وتنبئهم إليها في الوقت الحقيقي.

طرائق البحث ومواده:

سيجري العمل في هذه المقالة على مرحلتين متتاليتين بهدف تحديد الحالات الثلاثة السابقة لضربة القلب (PVC, PAC, NB)، وسيتم تحسين أداء كل مرحلة بشكل مستقل عن الأخرى مما يعكس تحسناً نهائياً على خوارزمية الكشف المقترحة كما يلي:

1. مرحلة كشف السمات لإشارة الـ ECG (Features Extraction): وهي مجموعة خصائص زمنية ومطالية لكل ضربة من ضربات القلب الموجودة في إشارة الـ ECG وسيتم تعريفها بالتفصيل في الفقرات اللاحقة، توجد خوارزميات مختلفة لاستخراج هذه السمات منها ما يعتمد العمل في المجال الزمني [12] [13]، ومنها ما يعتمد المجال الترددي [4]، أو باعتماد طرق هجينة [7] حيث أثبتت جدارة أكبر، لذلك سنستخدم تحويل الموجات Wavelet Transform وهو تحويل يجمع ما بين مزايا المعالجة الزمنية والمعالجة الترددية، وسيكون فعالاً جداً لإزالة الضجيج والإشارات غير المرغوبة من إشارة الـ ECG المُحصَّلة وبذلك يكون لدينا إشارة نظيفة يمكن استخراج السمات المطلوبة بالطرق المعروفة [7] [11] [12] [13]. ستكون هذه السمات بمثابة المداخل للمرحلة التالية حيث سيتم الاعتماد عليها لكشف نوع ضربة القلب، فالخطأ في تحديد السمات قد يعطي كسفاً خاطئاً للضربة.

2. مرحلة كشف المرض: ستتم هذه المرحلة بالاعتماد على الاستدلال العائم باستخدام الشبكات العصبونية ANFIS التي ستكشف المرض بالاعتماد على السمات المستخرجة في المرحلة السابقة، ستكون المساهمة الأساسية في

هذه المقالة هو طرح طريقة جديدة في استخدام الشبكات ANFIS في الكشف مما يزيد من نسبة نجاحها ودقته، حيث سيتم استخدام شبكتين ANFIS متعاقبتين يكون خرج الأولى دخل للثانية. تقوم الشبكة الأولى بفرز ضربات القلب إلى مجموعتين فقط هما مجموعة الضربات السليمة الطبيعية ومجموعة الضربات المريضة أو المعتلة بدون كشف نوع المرض؛ في حين تقوم الشبكة العصبونية الثانية بكشف نوع المرض في الضربات المريضة التي اكتشفتها الشبكة الأولى كما سنرى لاحقاً.


1 الجانب العلمي 1: كشف سمات ضربات القلب Features Extraction

يظهر الشكل (1) في الفقرة السابقة مثلاً لرسم تخطيط القلب الطبيعي، والذي يتألف من موجة P، مركّب QRS وموجة T. قد تكون موجة U الصغيرة أيضاً واضحة في بعض الأحيان. الموجة P هو التوقيع الكهربائي للتيار الذي يسبب انقباض الأذين. المركّب QRS يتوافق مع التيار الذي يسبب انقباض البطينين الأيسر والأيمن. تمثل الموجة T في عودة الاستقطاب إلى البطينين. والموجة U، وإن لم تكن دائماً واضحة، تمثل العضلات الحليمية أو الألياف العصبية. يعد وجود أو عدم وجود هذه الموجات وكذلك فترة QT والفاصلة PR كمعاملات ذات مغزى في فحص وتشخيص أمراض القلب والأوعية الدموية، لكن في هذه المقالة سيتم التركيز على سمات وخواص المركّب QRS التي يمكن من خلالها كشف عدم انتظام ضربات القلب ونوعها.

1 1 - سمات المركّب QRS

يمكن توصيف المركّب QRS بالسمات التالية:

1. السمة RR_2 : الزمن بين قمة (R) الحالية وقمة (R) اللاحقة انظر الشكل (3).
2. السمة RR_1 : الزمن بين قمة (R) الحالية وقمة (R) السابقة انظر الشكل (3).
3. السمة RR_0 : الزمن بين القمتين (R) السابقتين للقمة الحالية انظر الشكل (3).
4. السمة RR_M : الزمن الوسطي بين قمتين (R) متتاليتين.
5. السمة R_{01} : تُعرّف بالنسبة التالية $R_{01}=RR_0/RR_1$.
6. السمة R_{21} : تُعرّف بالنسبة التالية $R_{21}=RR_2/RR_1$.
7. السمة R_{M1} : تُعرّف بالنسبة التالية $R_{M1}=RR_M/RR_1$.



الشكل (3): تمثيل الأزمنة RR [7].


8. النموذج المرجعي الوسطي المقيس (Normalized) للمركب QRS الخاص بالمريض تحت الدراسة انظر

الشكل (4). يتم الحصول على ذلك باجتزاء الإشارات $(QRS_i)_{i=1,2,\dots,N}$ الموافقة لمواقع ضربات القلب من الإشارة ECG، حيث يؤخذ 140 ms قبل موقع الضربة و 70 ms بعد موقع الضربة من إشارة الـ ECG فيكون الطول الزمني لكل إشارة مركب QRS_i هو 210 ms، بعد ذلك يتم تقييس كل إشارة باستخدام المعادلة التالية:

$$QRSN_i = \frac{QRS_i - \min(QRS_i)}{\max(QRS_i) - \min(QRS_i)} \quad \text{for } i = 1, 2, \dots, N$$

حيث N عدد الضربات الكلي، و $QRSN_i$ إشارة المركب QRS المقيسة عند الضربة رقم (i) . يتم الحصول على النموذج الوسطي المقيس $QRSN$ من العلاقة:

$$QRSN = \frac{1}{N} \sum_{i=1}^N QRSN_i$$



الشكل (4): النموذج المرجعي الوسطي المقيس [7].

9. السمة Correlation1: تشابه الإشارة المقيسة للضربة الحالية $QRSN_i$ مع الإشارة السابقة $QRSN_{i-1}$.


10. السمة Correlation2: تشابه الإشارة المقيسة للضربة الحالية $QRSN_i$ مع الإشارة اللاحقة $QRSN_{i+1}$.

11. السمة CorrelationXY: تشابه الإشارة المقيسة للضربة الحالية $QRSN_i$ مع النموذج المرجعي الوسطي

المقيس $QRSN$.

12. السمة (A): وهي الزمن الفاصل بين أول مرور للمركب المقيس QRS بالقيمة 0.5 وبين مروره الثاني

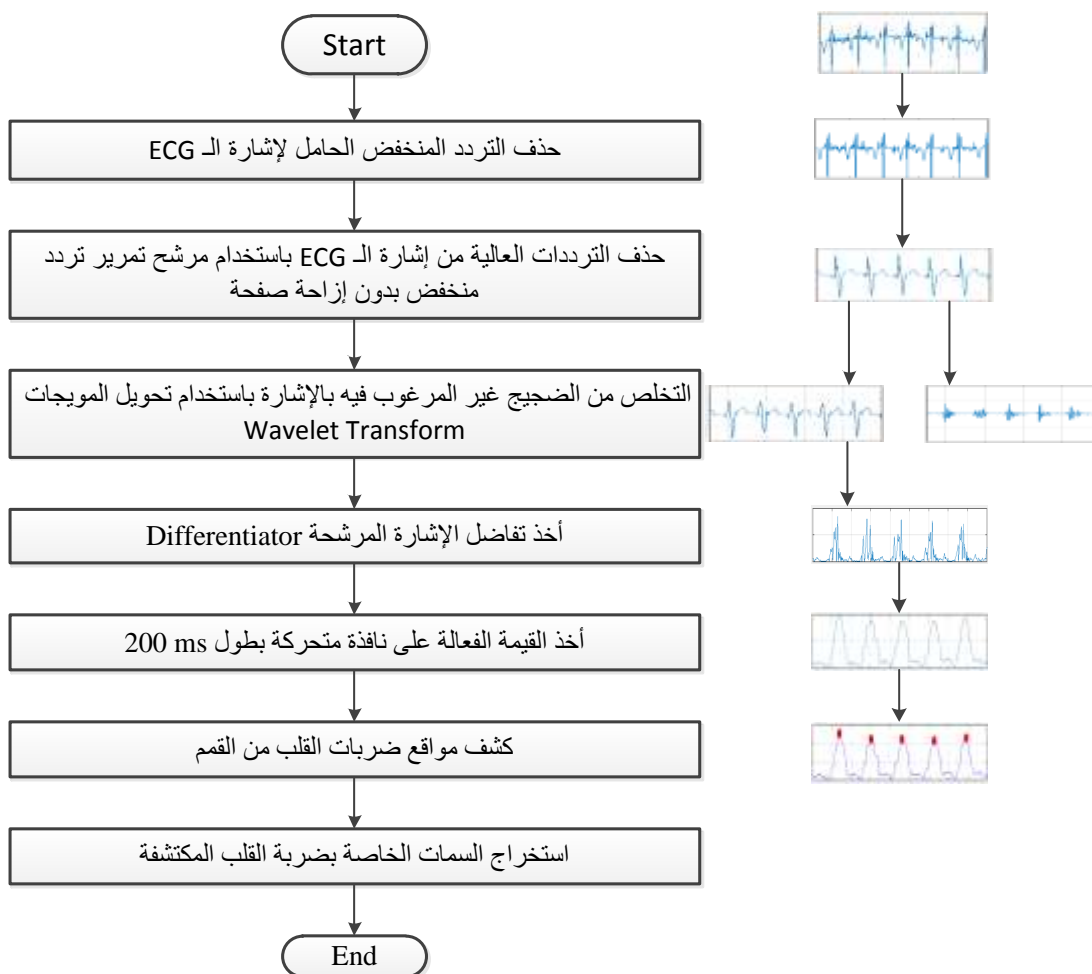
بنفس القيمة كما هو موضح بالشكل (5).



الشكل (5): السمة (A) [7].

1 2 - استخلاص سمات المركب QRS

يمثل كشف مواقع المركبات QRS الخطوة الأساسية في كشف السمات الخاصة بكل مركب، فمن خلال تعريفها في الفقرة السابقة يُلاحظ كيف يصبح حسابها سهلاً بالاعتماد على موقع المركب QRS. سيتم في هذه الفقرة التركيز على خوارزمية كشف مواقع المركبات QRS ضمن إشارة رسم القلب ECG مما يفضي بالتالي إلى استخلاص هذه السمات الموافقة؛ تمر خوارزمية الكشف بالخطوات الموضحة في الشكل (6) (انظر [12][11][17]).



الشكل (6): المخطط العام لكشف السمات.

1 2 1 حذف التردد المنخفض الحامل لإشارة الـ ECG

تكون إشارة الـ ECG المفيدة محمولة على إشارة حاملة ذات تردد منخفض أقل من 0.1 Hz، تشكل هذه الإشارة إعاقة كبيرة عند البحث عن السمات لذلك يتم حذفها عادةً على مرحلتين:

1. المرحلة الأولى: هي مرحلة استخراج الإشارة الحاملة Base line signal.
2. المرحلة الثانية: يتم فيها حذف القيمة المتوسطة المتبقية من إشارة الـ ECG بعد حذف الإشارة الحاملة منها. عادةً ما تتراكب على إشارة القلب الكهربائية إشارات بتردد منخفض بحدود 0.5 هيرتز تدعى بالإشارة الحاملة Base line signal، تنتج غالباً عن حركات صدر المريض أثناء التنفس أو حركات جسم المريض الميكانيكية، لا بد من إزالتها للقيام باستخراج خصائص الإشارة بالشكل الأمثل، وذلك دون المساس بالمعلومات الخاصة بكل ضربة قلب موجودة في الإشارة الأساسية. للقيام بإزالة الإشارة الحاملة استخدمنا مرشح الميديان median filter والذي يقوم بمعالجة الإشارة وفق نوافذ بأطوال زمنية محددة، حيث يعتمد معالجة كل عنصر من عناصر الإشارة اعتماداً على قيم جيران العنصر حيث يستبدل قيمة العنصر المتوسط من بين عناصر النافذة بعد ترتيبها تصاعدياً، عادةً ما يتم استخدام مرشح الميديان لحذف الإشارة الحاملة على عدة مراحل، وسُتعمد المراحل المذكورة في المرجع [11] كالآتي:

1. يُطبَّق مرشح الميديان بنافاذة ذات طول زمني 200 ميلي ثانية فيتم بذلك اعتبار قيم المركب QRS وقيمة الموجة P قيماً شاذة، يتم في هذه المرحلة ترشيح الإشارة برتبة n تكافئ عدد العينات من الإشارة الموجودة ضمن نافذة زمنية طولها 200 ms، يكون خرج هذه المرحلة الإشارة base_line1.
2. بعد ذلك يتم ترشيح الإشارة base_line1 باستخدام نفس المرشح لكن برتبة n تكافئ عدد العينات من الإشارة الموجودة ضمن نافذة زمنية طولها 600 ms، ليتم الحصول على الإشارة الحاملة النهائية base_line.
3. تُطرح الإشارة الحاملة النهائية base_line من الإشارة الأصلية للحصول على إشارة قلب جديدة ECG_new1.

يتم حذف القيمة المتوسطة المتبقية في الإشارة الجديدة ECG_new1 من خلال حذف مباشر للقيمة المتوسطة لهذه الإشارة على مجالات زمنية بطول 1 ثانية فنحصل على الإشارة (ECG_new2).

1 2 2 حذف الترددات العالية من الإشارة ECG_new2

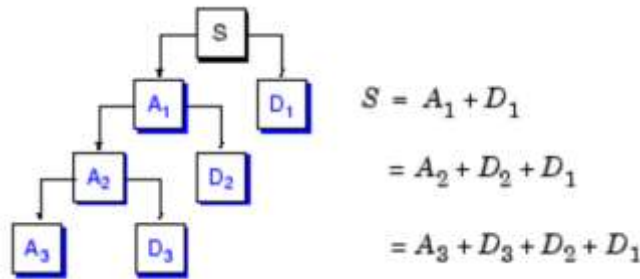
إن المعلومات المفيدة في إشارة الـ ECG الناتجة من المرحلة السابقة ECG_new2 موجودة في الترددات الأقل من 30 Hz لذلك من المفيد التخلص من الترددات الأعلى مع الحفاظ على عدم إضافة تأخيرات زمنية Delay بين دخل وخرج المرشح، لتحقيق ذلك يتم استخدام مرشح تمرير تردد منخفض بدون إزاحة صفحة zero-phase low pass filter فنحصل على الإشارة ECG_smooth1.

1 2 3 الترشيح النهائي باستخدام تحويل المويجات Wavelet Transform

يُعتبر تحويل المويجات من الطرق القوية جداً المستخدمة لفصل مركبات الضجيج في الإشارة، لكن بشرط أن نكون على دراية كافية بأنواع الضجيج غير المرغوب فيها المتواجدة مع الإشارة المفيدة لنعرف عند أي مستوى يجب التوقف عنده في الترشيح بالمويجات، ويوجد الكثير من المراجع التي تتطرق بالتفصيل لهذا التحويل [17].
يعمل هذا التحويل على مستويات ويكون دخل كل مستوى n هو الإشارة المفيدة A_{n-1} المستخلصة من المستوى السابق n-1 ويكون الخرج هو عبارة عن إشارة مفيدة أخرى A_n وإشارة ضجيج أخرى D_n ويكون لدينا في كل مستوى العلاقة التالية محققة:

$$A_{n-1} = A_n + D_n \quad (1)$$

يوضح الشكل (7) هذه العلاقة بشكل جلي، حيث سيتم تطبيقها على الإشارة ECG_smooth1 من المرحلة السابقة.



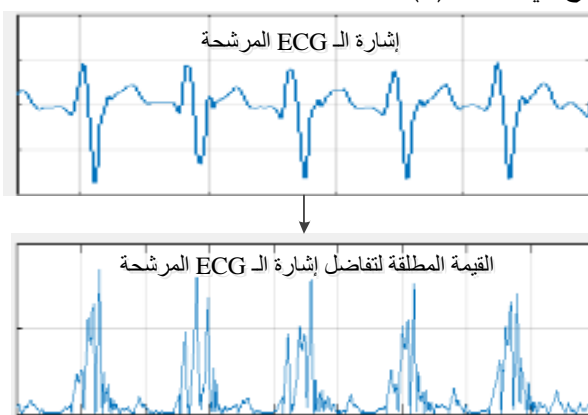
الشكل (7): آلية الترشيح بالمويجات.

بالإضافة إلى رقم المستوى الواجب التوقف عنده توجد هناك نقطة هامة يجب تحديدها ليكون الترشيح فعالاً، هي مجموعة توابع المويجات wavelet functions المستخدمة في ترشيح الإشارة.

أجمعت كل الأبحاث التي تستخدم تحويل الموجات في ترشيح إشارة الـ ECG على أن المجموعة 'DB4' من موجات Daubechies Wavelets هي الأفضل [11][12][13]. تم استخدام الإشارة المفيدة المستخرجة من المستوى الرابع A_4 كإشارة سيتم العمل عليها لكشف مواقع المركبات QRS، حيث أن هذا المستوى هو الذي أعطى أفضل النتائج تجريبياً في كشف السمات وهذا متوافق مع نتائج المقالات السابقة مثل [11].

1 2 4 مرحلة التفاضل

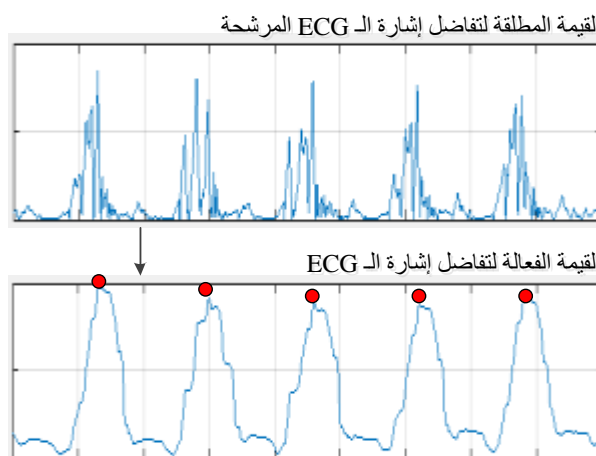
إنّ الديناميك الأساسي لإشارة الـ ECG بعد إجراء كل الترشيح السابق عليها هو مركز زمنياً في منطقة كل ضربة قلب وبين كل ضربتي قلب تكون الإشارة شبه صفرية، وبالتالي من المنطقي والعملية أن يُستخدم التفاضل لكشف مناطق الضربات كما هو موضح في الشكل (8).



الشكل (8): مرحلة التفاضل.

1 2 5 القيمة الفعالة على نافذة زمنية متحركة

يتم في هذه المرحلة أخذ القيمة الفعالة لإشارة تفاضل الـ ECG المستنتجة من المرحلة السابقة، وذلك على نافذة زمنية ثابتة بطول 200 ms تتحرك على طول زمن الإشارة الأصلي كما هو موضح في الشكل (9).



الشكل (9): القيمة الفعالة لتفاضل إشارة الـ ECG المرشحة.


تكون مواقع قمم إشارة القيمة الفعالة لتفاضل إشارة الـ ECG المرشحة هي عبارة عن مواقع المركبات QRS كما هو موضح في الشكل (9)، وبعد ذلك يمكن استخلاص سمات كل مركب على جدي.

2 الجانِب العلمي 2: استخدام شبكة ANFIS في تصنيف ضربات القلب

2 1 - نظرية المجموعات العائمة Fuzzy Set Theory

تؤمن المجموعات العائمة fuzzy sets إطار عمل لإشراك المعرفة البشرية في حل المشاكل. في نظرية المجموعات العائمة، تُرفق كل مجموعة بتابع يسمى تابع الانتماء لهذه المجموعة membership function. بالمقارنة مع المجموعات الثنائية التقليدية binary sets حيث يكون الانتماء إما '1' للإشارة إلى القيمة الصحيحة true أو '0' للإشارة إلى القيمة الخاطئة false، تتراوح متحولات المنطق العائم بين 0 و 1، أي أن المنطق العائم يتعامل مع الاستنتاج التقريبي بدلاً من الاستنتاج الدقيق [18]. يمكن شرح نظرية المجموعات العائمة كما يلي:

لتكن Z مجموعة من العناصر z أي $Z=\{z\}$ ، ولتكن A مجموعة عائمة في معرفة بتابع الانتماء $\mu_A(z)$ الذي يقرن كل عنصر من Z بعدد حقيقي في المجال $[0, 1]$. يمكن للعناصر z أن تكون منتمية بشكل كامل أي $(\mu_A(z)=1)$ أو جزئي $(0 \leq \mu_A(z) \leq 1)$ أو غير منتمية $(\mu_A(z)=0)$ وذلك بالنسبة لتابع الانتماء $\mu_A(z)$. توجد عدة أشكال لتتابع الانتماء حيث تتنوع تبعاً للمسألة المطروحة ومن أهمها: الغوسي Gaussian، الغوسي الجرسى Gaussian-bell، المثلث Triangle و شبه المنحرف Trapezoidal كما هو مبين في الشكل (10).



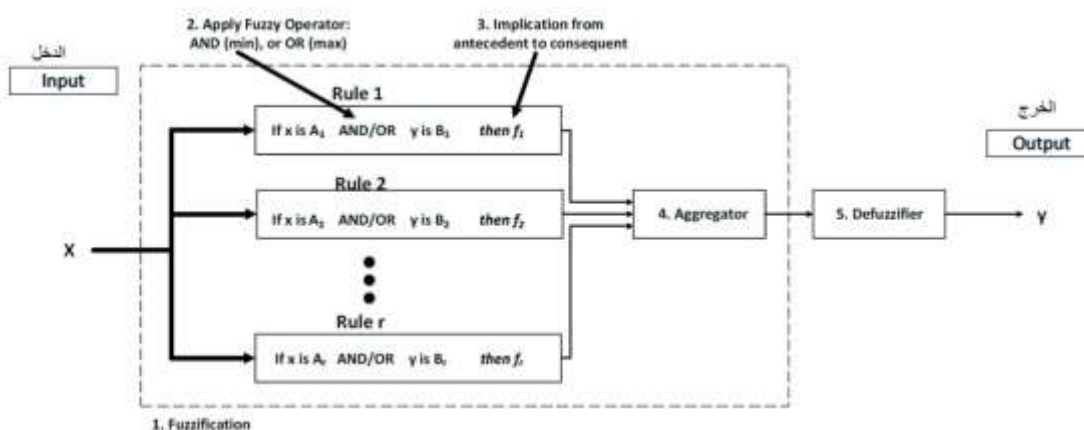
الشكل (10): بعض أشكال توابع الانتماء

يقوم نظام الاستدلال العائم Fuzzy Inference System (FIS) بمقابلة الدخل المعطى مع الخرج الموافق باستخدام المجموعات العائمة fuzzy sets. يبين الشكل (11) المخطط الصندوقى block diagram لنظام الاستدلال العائم FIS، حيث يتضمن هذا النظام خمس خطوات:

1. تعويم Fuzzification متحولات الدخل input variables.
2. تطبيق المعامل العائم fuzzy operator (AND أو OR) على عناصر القواعد if-then.
3. حساب نتيجة القواعد Implication process.
4. تجميع Aggregation نتائج كل القواعد.
5. عكس التعويم أو التحديد Defuzzification.

يجري في مرحلة التعويم Fuzzification حساب قيمة انتماء المداخل inputs إلى المجموعة العائمة باستخدام توابع الانتماء membership functions. عند تطبيق المعامل العائم fuzzy operator يتم إيجاد نتيجة الشرط if لكل قاعدة rule، حيث يقوم المعامل AND بأخذ القيمة الصغرى minimum لقيم توابع الانتماء عند الدخل الموافق، في حين يقوم المعامل OR بأخذ القيمة الكبرى maximum لقيم توابع الانتماء عند الدخل الموافق. في المرحلة الثالثة implication process يتم حساب نتيجة كل قاعدة then وإعطاء كل قاعدة وزناً weight معيناً؛ تُعتبر هذه النتيجة (تسمى consequent) مجموعة عائمة أيضاً ويُعبّر عنها بتابع انتماء يقوم بتثقيل الخواص اللفظية linguistic characteristics الموافقة لكل قاعدة. في المرحلة الرابعة يتم تجميع جميع مخارج القواعد في مجموعة عائمة واحدة. هناك عدة طرق

للقيام بعملية التجميع aggregation منها: القيمة الكبرى maximum و (أو) الاحتمالية probabilistic OR وهي ببساطة جمع قيم خرج القواعد. المرحلة الأخيرة Defuzzification وتعني عكس التعويم أو التحديد وتقوم بتوليد قيمة مفردة رقمية. أكثر الطرق شيوعاً في هذه العملية هي حساب المركز المتوسط centroid calculation التي تقوم بحساب مركز السطح الواقع تحت المنحني الناتج من عملية التجميع Aggregation. هناك طرق أخرى يمكن للقارئ الرجوع إليها في [19].



الشكل (11): المخطط الصندوقي block diagram لنظام الاستدلال العائم FIS.

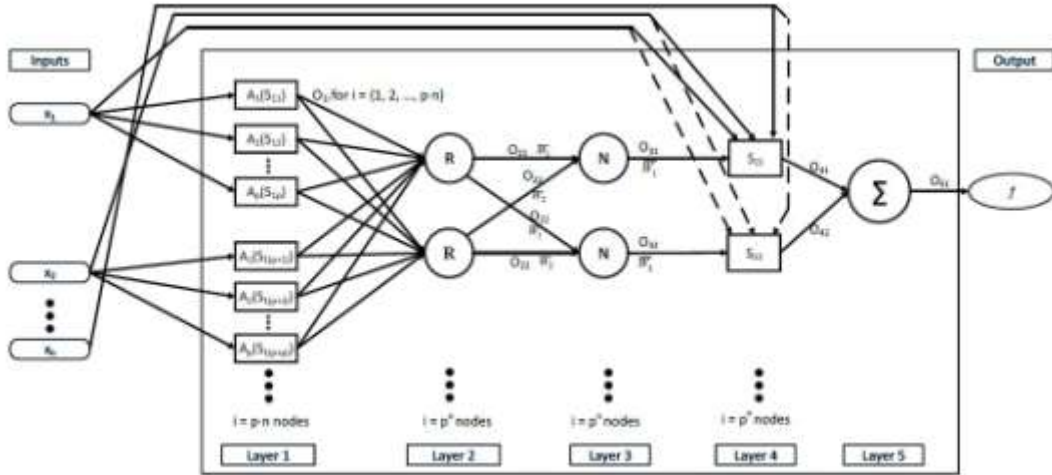
هناك أنواع متعددة لنظم الاستدلال العائمة FIS، من أكثرها انتشاراً: نماذج مامداني Mamdani و نماذج سوجينو Sugeno نسبة للعلماء الذين اقترحوهما. يمثل النظام الموضح في الشكل (11) نموذج Mamdani، في حين يتميز نموذج Sugeno بأنه لا يُحدد قيمة الخرج بناءً على تابع انتماء بل كثنائيات أو تمثيل خطي.

2 - خوارزمية ANFIS أو ANFIS algorithm

الـ ANFIS هي اختصار لـ Adaptive Neuro-Fuzzy Inference System وهي مزيج من نظام الاستدلال العائم FIS والشبكات العصبونية Neural Networks NN، والهدف من وجود الشبكة العصبونية توليف tuning القواعد (if-then) وتوابع الانتماء membership functions.

سيتم في هذه الدراسة استخدام ANFIS من نوع Sugeno نظراً لكفاءتها الحسابية ولأنها تعمل بشكل جيد مع طرق الأمثلة optimization والتكيف adaptive techniques، بالإضافة لكونها مناسبة جداً للتحليل الرياضي، في حين تعاني الأنظمة التي تستخدم Mamdani من عدم كفاءتها الحسابية إضافة إلى حاجتها للعامل البشري لإضافة بعض القواعد.

يتألف نظام ANFIS من نوع Sugeno من خمس طبقات كما يبين الشكل (12)، حيث يمثل المستطيل العقدة المتغيرة أو المتكيفة adaptive node. سنقوم فيما يلي بشرح مفصل لكل طبقة. بفرض n هو عدد المداخل inputs و $z=\{1,2,3,4,5\}$ تمثل طبقات شبكة ANFIS. نرمز لخرج العقدة i من الطبقة z بالرمز O_{zi} . نرمز بـ p لعدد توابع الانتماء الخاصة بكل دخل.



الشكل (12): شكل توضيحي لشبكة ANFIS من نوع Sugeno

1 2 2 - الطبقة الأولى Layer 1

يُطلق على هذه الطبقة طبقة التعويم Fuzzification نرمز لخرج هذه الطبقة بـ O_{1i} حيث $i=\{1,2,\dots,p\}$. هي عبارة عن تابع انتماء membership function الذي يحدد درجة انتماء الدخل رقم k للمجموعة العائمة A_k حيث $k=\{1,2,\dots,p\}$. يتم التعبير عن هذه التوابع بالشكل $\mu_{A_k}(x_i; \{a,b,c,d,\dots\})$ من أجل $t=\{1,2,\dots,n\}$ حيث توزع الـ n مدخل على p تابع انتماء. كل تابع انتماء هو تابع للسمة feature x_m :

$$O_{1i} = \mu_{A_k}(x_m; \{a_i, b_i, c_i, d_i, \dots\})$$

تمثل توابع الانتماء المعاملات السابقة antecedent parameters لشبكة ANFIS الموصّفة بـ $S_{1i}=\{a_i, b_i, c_i, d_i, \dots\}$

$$O_{1i} = \mu_{A_k}(x_m; S_{1i})$$

ويكون التوصيف الجديد للخرج O_{1i} على الشكل التالي:

تتغير العقد في هذه الطبقة adaptive node باستمرار تبعاً للدخل، وهناك عدة أشكال لتوابع الانتماء المستخدمة

في شبكة ANFIS من نوع Sugeno (عد إلى الشكل (10)).

عدد المعاملات الناتجة من الطبقة الأولى والتي تعرف لتوابع الانتماء يساوي $n \times p \times n$ ، حيث l هي عدد

الثوابت التي تعرف لتابع الانتماء (مثلاً $l=3$ من أجل تابع الانتماء المثلث و $l=4$ من أجل تابع الانتماء شبه المنحرف).

2 2 2 - الطبقة الثانية Layer 2

يطلق على هذه الطبقة طبقة القواعد rule layer. يرمز لخرج هذه الطبقة بـ O_{2i} حيث $i=\{1,2,\dots,p\}$ هي

القواعد المعرفة إما بـ AND أي minimum أو بـ OR أي maximum، بعبارة أخرى: $R=\{\min[\text{AND}]\}$ or $R=\{\max[\text{OR}]\}$.

بفرض W_i تمثل الأوزان الناتجة عن طبقة القواعد فيكون:

$$O_{2i} = W_i = \text{rule}\{A_k\}$$

3 2 2 - الطبقة الثالثة Layer 3

وهي طبقة التقييس normalization layer. ليكن N ممثلاً للتقييس في الطبقة الثالثة كما في الشكل (12). يُرمز

لخرج هذه الطبقة بـ O_{3i} حيث $i=\{1,2,\dots,p\}$ ، ولتكن \bar{W}_i الوزن المقيس normalized weight لكل قاعدة أي:

$$O_{3i} = \bar{W}_i = \frac{W_i}{W_1 + W_2 + \dots + W_p}$$

يضمن التقييس التقارب المستقر للأوزان والانحرافات، وتقلل من وقت عملية فك التعميم أو التحديد Defuzzification.

2 2 4 الطبقة الرابعة Layer 4

هذه هي طبقة فك التعميم أو التحديد Defuzzification. يرمز لخرج هذه الطبقة بـ O_{4i} حيث $i=\{1,2,\dots,p\}$. لنكن $S_{2i}=\{q_{1i},q_{2i},\dots,q_{ni}\}$ المعاملات الخاصة بها، نعرف تابعاً خطياً f_i كمجموع لجداءات الدخل بالمعاملات S_{2i} كما يلي:

$$f_i = q_{1i}x_1 + q_{2i}x_2 + \dots + q_{ni}x_n + r_i$$

أما الخرج O_{4i} فهو عبارة عن جداء الوزن المقيس \bar{w}_i بالتابع الخطي f_i :

$$O_{4i} = \bar{w}_i f_i$$

ويكون عدد المعاملات الناتجة مساوياً $(n+1).p^n$ ، بسبب وجود الانحرافات r_i بالإضافة للمعاملات S_{2i} .

2 2 5 الطبقة الخامسة Layer 5

هذه هي طبقة الجمع summation layer. لها خرج وحيد يُرمز له بـ O_{51} ؛ وهو عبارة عن تجميع aggregation لكل المخارج التي تم فك تعويمها defuzzified outputs من الطبقة السابقة O_{4i} ، ويحسب باستخدام طريقة مركز النقل:

$$O_{51} = \sum_{i=1}^{p^n} O_{4i} = \sum_{i=1}^{p^n} \bar{w}_i f_i = \frac{\sum_{i=1}^{p^n} w_i f_i}{\sum_{i=1}^{p^n} w_i}$$

2 3 - خوارزمية التعلم الهجينة Hybrid Learning Algorithm


إنَّ تحديد القيم الأمثلية optimal values لبارامترات شبكة ANFIS يتم عن طريق خوارزمية تعلم هجينة كما في [121]. تجمع هذه الخوارزمية بين طريقة التقدير عن طريق المربعات الأصغرية (LSE) least-squares estimator وطريقة البث العكسي باستخدام الهبوط التدريجي back-propagation gradient descent method ولذلك تسمى هجينة hybrid. عند الانتقال المباشر forward pass تعتبر المعاملات السابقة antecedent parameters ثابتة بينما يتم تحديد المعاملات اللاحقة consequent parameters باستخدام خوارزمية LSE. عند الانتقال العكسي backward pass تُعتبر المعاملات اللاحقة ثابتة بينما تُحدد المعاملات السابقة باستخدام طريقة البث العكسي من خلال الهبوط. تستخدم خوارزمية التعلم الهجينة في التعلم بشكل مباشر online أو بشكل غير مباشر offline، وقد تم في هذه الدراسة استخدام هذه الخوارزمية بشكل غير مباشر كما هو مشروح في [122]، أي استخدامنا قيم مسجلة للدخل والخرج كما سنرى لاحقاً. من فوائد هذه الخوارزمية أنها تقوم بحساب المعاملات اللاحقة بشكل أمثلي، بهذه الطريقة يمكن تقليص عدد الأبعاد المستخدم في خوارزمية الهبوط التدريجي وأيضاً تسريع معدل تقارب rate of convergence المعاملات.

2 4 - استخدام شبكة ANFIS في تصنيف ضربات القلب

لاستخدام شبكة ANFIS في تصنيف ضربات القلب من خلال إشارة الـ ECG يجب تحديد مداخل ومخارج الشبكة. وقد تم في هذه الدراسة استخدام شبكتين متلاحقتين من نوع ANFIS كما يبين الشكل (13)، حيث تقوم الشبكة الأولى بالتمييز بين الضربات الطبيعية Normal beats والضربات المعنلة (PVC أو APC) بينما تقوم الشبكة الثانية بالتمييز بين PVC و APC.

لتحقيق المخطط السابق يجب في البداية تدريب training كل من الشبكتين السابقتين على ضربات معروفة النوع مسبقاً. بعد التدريب نقوم بإدخال ضربات غير معروفة النوع ويقوم النظام المقترح في الشكل (13) بتصنيفها. لتقييم

أداء نظام التصنيف هناك عدد من المعايير المعمول بها عالمياً [120]. تعتمد هذه المعايير على حساب عدد من المقادير الإحصائية التالية:



2 4 1- الحساسية Sensitivity:

تعبر الحساسية Se عن كشف الضربة المعتلة (PVC أو APC) وتحسب كنسبة مئوية على الشكل التالي:

$$Se = 100 \times \frac{TP}{TP + FN}$$

TP هو عدد التصنيفات الصحيحة في حالة المرض، أي أن يتم تصنيف ضربات PVC على أنها PVC و APC على أنها APC، و FN هو عدد التصنيفات الخاطئة في حالة المرض، أي أن يتم تصنيف ضربات PVC أو APC على أنها طبيعية Normal. كلما اقتربت هذه النسبة من 100% كان التصنيف أكثر دقة. يتفرع من الشكل العام السابق لعلاقة حساب الحساسية شكلين فرعيين هما:

$Se1$ حساسية كشف الضربات المعتلة من النوع PVC وتحسب بالعلاقة:

$$Se1 = 100 \times \frac{TP1}{TP1 + FN1}$$

$TP1$ هو عدد التصنيفات الصحيحة في حالة المرض PVC، أي أن يتم تصنيف ضربات PVC على أنها PVC، $FN1$ هو عدد التصنيفات الخاطئة في حالة المرض PVC، أي أن يتم تصنيف ضربات PVC على أنها طبيعية. $Se2$ حساسية كشف الضربات المعتلة من النوع PAC وتحسب بالعلاقة:

$$Se2 = 100 \times \frac{TP2}{TP2 + FN2}$$

$TP2$ هو عدد التصنيفات الصحيحة في حالة المرض APC، أي أن يتم تصنيف ضربات PAC على أنها APC، $FN2$ هو عدد التصنيفات الخاطئة في حالة المرض APC، أي أن يتم تصنيف ضربات APC على أنها طبيعية.

2 4 2- التحديدية Specificity

تعبر التحديدية Sp عن النسبة المئوية لعدد كشف الضربات غير المعتلة وتحسب بالعلاقة التالية:

$$Sp = 100 \times \frac{TN}{TN + FP}$$

TN هو عدد التصنيفات الصحيحة في الحالة الطبيعية، أي أن يتم تصنيف الضربات الطبيعية على أنها طبيعية، و FP هو عدد التصنيفات الخاطئة في الحالة الطبيعية، أي أن يتم تصنيف ضربات طبيعية على أنها معتلة (PVC أو APC). كلما اقتربت هذه النسبة من 100% كان التصنيف أكثر دقة.

2 4 3- الدقة Accuracy أو التصنيف الصحيح Correct Classification

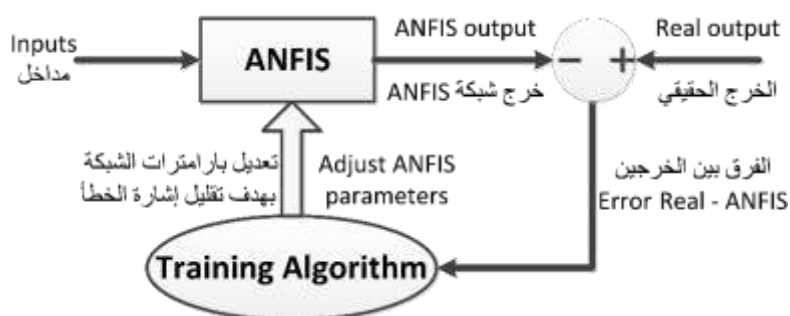
التصنيف الصحيح CC هو النسبة المئوية للتصنيفات الصحيحة وتحسب من العلاقة:

$$CC = 100 \times \frac{TN + TP}{TN + TP + FN + FP}$$

حيث $(TP = TP1 + TP2)$ و $(FN = FN1 + FN2)$. كلما اقتربت هذه النسبة من 100% كان التصنيف أكثر دقة.

2 5 - تدريب شبكة ANFIS (ANFIS Training)

تتطلب عملية تدريب أي شبكة تحضير معلومات تتضمن إشارة الدخل inputs وإشارة الخرج outputs الموافقة لكل دخل. تقوم خوارزمية التدريب بتغيير المعاملات الداخلية لشبكة ANFIS بحيث يتطابق خرج الشبكة مع الخرج المرجعي ضمن مجال مقبول، وعند ذلك يمكننا القول أن الشبكة قد تعلمت وأصبحت قادرة على التنبؤ بإشارة الخرج من أجل أي دخل جديد لم تتعلم (تتدرب) عليه سابقاً. يبين الشكل (14) المخطط العام لعملية تدريب شبكة ANFIS.



الشكل (14): المخطط العام لعملية تدريب شبكة ANFIS.

2 6 - تحضير المعلومات لتدريب شبكة ANFIS

سيتم تدريب الشبكة على عدة تسجيلات لإشارة الـ ECG لعدة مرضى مختلفين من موقع قاعدة البيانات المفتوحة [8]، حيث يضم كل تسجيل ملفاً مرفقاً بعدد ضربات القلب المسجلة فيه وموضعها الزمني ضمن الإشارة وبالإضافة إلى نوعها (Normal, PVC, APC) مما سيؤمن الخرج الحقيقي أو المرجعي الذي سيتم المقارنة عليه أثناء عملية التدريب، انظر الشكل (14). سيتم بعد ذلك استخراج سمات جميع ضربات القلب باستخدام الخوارزمية التي تم استعراضها سابقاً، فيكون قد أصبح لدينا مصفوفة كبيرة نسميها السجل الكبير Big_record عدد أسطرها هو عدد ضربات القلب المحصلة من كل المرضى المختارين للتدريب، وعدد أعمدها هو عدد السمات الاثنى عشرة بالإضافة إلى نوع الضربة أي لدينا ثلاث عشرة عموداً. لقد تبين لنا من خلال التجارب المتكررة أنه باستخدام السبعة سمات التالية $(RR_0, RR_1, RR_2, R_{01}, R_{21}, R_{M1}, A)$ يمكن كشف نوع الضربة وأن استخدام السمات الأخرى كمداخل إضافية للشبكة لم يزد أو يحسن من دقة كشفها. يجري بعد ذلك تجزئة السمات في السجل الكبير إلى ثلاث مصفوفات بناء على نوع الضربة (Normal, PVC, APC)، هذه المصفوفات هي: N_data, V_data, A_data . بعد ذلك يتم تشكيل مصفوفة التدريب train_data من المصفوفات الثلاثة السابقة بشكل عشوائي أي يتم اختيار الأسطر من هذه الأشعة بشكل عشوائي. يحوي train_data عدد متساوي من كل من الضربات (Normal, PVC, APC) وذلك لضمان تدريب شبكة ANFIS بشكل متكافئ على الضربات الثلاثة.

يتم تدريب الشبكة الأولى ANFIS1 الموضحة في الشكل (13) على كامل مصفوفة التدريب لتصبح قادرة على كشف الضربات الطبيعية من المعتلة بغض النظر عن اعتلالها، في حين يتم تدريب الشبكة الثانية ANFIS2

الضربات المعتلة فقط الموجودة في مصفوفة التدريب لتستطيع كشف نوع المرض في الضربة المعتلة (PVC or APC)؛
فبذلك يتم تحقيق المنهجية المقترحة لنظام تصنيف الضربات باستخدام شبكات ANFIS الموضحة في الشكل (13).
سيتم تقييم أداء نظام التصنيف الجديد على مرضى آخرين لم يدخلوا في مصفوفة التدريب كما سنرى في الفقرة
التالية.

3 النتائج (تقييم أداء المصنّف الجديد)

لقد تم بناء جميع الخوارزميات السابقة ضمن بيئة ماتلاب نسخة 2013b على حاسب شخصي يعمل بنظام
التشغيل Windows7 – 64bits.

تم إعداد مصفوفة التدريب من السجلات {228,223,221,220,209,200,119,116,115,106} المأخوذة من قاعدة
البيانات المفتوحة [18] والتي سيتم استخدامها لتدريب شبكتي الـ ANFIS -انظر الشكل (13)- بهدف حساب معاملات
توابع الانتماء فيها باستخدام خوارزمية التدريب المذكورة في الفقرة (2-6-)، وبعد ذلك تم إجراء مقارنة بين المصنّف
الجديد بعد حساب معاملاته والمصنّف المطروح في المرجع [16] حيث قام بإجراء عملية التصنيف باستخدام الـ ANFIS،
وذلك بالاعتماد على سجلات مشتركة بين المصنّفين {100,116,200,209,223,234} وسجلات أخرى لم تستخدم في
المرجع [16] ولا في سجلات التدريب.

يبين الجدول التالي المقادير الإحصائية (الحساسية Se₂, Se₁، التحديدية Sp، الدقة CC) المحسوبة لكل سجل
من أجل المصنّف الجديد ومن أجل مصنّف المرجع [16].

نلاحظ أن دقة المصنّف الجديد الوسطية %97.56 أعلى من الدقة الوسطية التي تم التوصل إليها في المرجع
[16] حيث كانت %95.91، كما أنّ دقة المصنّف الجديد أعلى من الدقة المرجع [16] في كل السجلات المشتركة.
يجدر بالذكر أيضاً أنّ الدقة الناتجة أعلى من الدقات التي تم الوصول إليها في فقرة الدراسة المرجعية مع أنه تم
استخدام سبع سمات فقط كمدخل لـ شبكتين ANFIS1 و ANFIS2 التي تم تطويرهما في هذه المقالة هذا يعكس تعقيد
حسابي أقل.

جدول 1: مقارنة بين المصنّف الجديد ومصنّف المرجع [16].

نتائج مصنّف المرجع [16]				نتائج المصنّف الجديد المقترح				رقم السجل
CC (%)	Sp (%)	Se ₂ (%)	Se ₁ (%)	CC (%)	Sp (%)	Se ₂ (%)	Se ₁ (%)	
97.30	96.15	95.75	100.00	99.96	99.96	100.00	100.00	100
97.33	95.26	100.00	96.74	99.00	98.96	100.00	100.00	116
93.44	89.36	93.33	97.62	92.06	88.56	100.00	99.38	200
95.16	93.25	95.40	96.82	-----	-----	-----	-----	201
97.44	97.23	95.09	100.00	95.53	94.92	99.74	100.00	209
96.86	97.01	96.27	97.31	-----	-----	-----	-----	210
96.25	95.11	97.15	96.48	97.33	98.15	95.71	93.78	223
-----	-----	-----	-----	98.41	98.34	100.00	100.00	812
-----	-----	-----	-----	98.89	98.89	100.00	100.00	809
-----	-----	-----	-----	97.22	96.73	100.00	99.45	228
93.86	94.59	90.71	96.29	-----	-----	-----	-----	233
95.54	92.75	93.87	100.00	99.63	99.62	100.00	100.00	234
95.91	94.52	95.29	97.92	97.56	97.13	99.50	99.18	المتوسط (%)

الاستنتاجات والتوصيات:

لقد تم في هذه المقالة تطوير مصنّف جديد مبني على خوارزميات الاستدلال العائم باستخدام الشبكات العصبونية ANFIS بهدف تحديد الضربات المعتلة ضمن إشارة القلب الـ ECG بالإضافة إلى نوع مرضها (PVC , APC) وذلك بعد استخراج سمات كل ضربة من ضربات القلب لتكون مداخل للمصنّف المطوّر . أثبت المصنّف الجديد فعالية أعلى من المصنّفات المعروفة عالمياً من حيث الدقة التي تم توصّل إليها حيث بلغت دقته الوسطية %97.56. كما استخدم المصنّف الجديد عدد سمات أقل (سبع سمات) لكشف نوع ضربة القلب مقارنةً بعدد السمات المستخدمة في المصنّفات السابقة المعتمدة على الشبكات العصبونية؛ هذا ما يعطي للمصنّف الجديد تعقيد حسابي أقل مقارنةً بغيره.

المراجع:

- [1] FRANCIS M., JUNE E., WILLIAM B., JOHN C. "Abc Ofclinical Electrocardiography". BMJ Books, London. (2003).
- [2] SHEN T. ; TOMPKINS W. , *Biometric Statistical Study of One-Lead ECG Features and Body Mass Index (BMI)*, Engineering in Medicine and Biology 27th Annual Conference, Shanghai, China, September 1-4. , (2005).
- [3] SZCZEPA A., SAEED K. AND FERSCHA A. "A New Method for ECG Signal Feature Extraction". Lecture Notes in Computer Science, Vol. 6375, (2010), pp. 334-341.
- [4] SUMATHI S. AND SANAVULLAH M. "A New Technique of ECG Feature Extraction and Classification by Wavelet Transform and ANFIS". International Journal of Computational Intelligence Research. Vol. 6, No.1, (2010), pp. 153–163.
- [5] Mazomenos B., BISWAS D., ACHARYYA A., MAHARATNA T., ROSENGARTEN J., MORGAN J., CURZEN N. "A Low-Complexity ECG Feature Extraction Algorithm for Mobile Healthcare Applications", IEEE Transactions on Information Technology in Biomedicine, Vol.17, No.2, (2011), pp 459-469.
- [6] BENALI R. AND CHIKH M. "Neuro-Fuzzy Classifier For Cardiac Arrhythmiasrecognition", Journal of Theoretical & Applied Information Technology, Vol. 5 Issue 5, (2009), p562.
- [7] ROMANO H., LACIAR E. AND CORREA R. (2011), "Development of An Algorithm for Heartbeats Detection and Classification in Holter Records Based on Temporal and Morphological Features", Journal of Physics: Conference Series 332 , Issue 1
- [8] MIT-BIH Arrhythmia Database Directory (Records), Boston's BethHospital, <http://www.physionet.com> (2013).
- [9] YEY Y., CHIANG T. ; LIN H. "Principal Component Analysis Method for Detection and Classification of ECG Beat", Bioinformatics and Bioengineering, IEEE 11th International Conference, (2011), pp.318-322.
- [10] STAMKOPOULOS T., DIAMANTARAS K., .MAGLAVERAS N. ; STRINTZIS, M. "ECG analysis using nonlinear PCA neural networks for ischemia detection", IEEE Transactions on Signal Processing, Vol.46, Issue: 11, (1998), pp3058 - 3067.
- [11] MEHTA, PRIYANKA, AND MONIKA KUMARI. "QRS complex detection of ECG signal using wavelet transform." International Journal of Applied Engineering Research 7.11: (2012), 1889-1893.
- [12] NAVARIA, ARUN, ; NEELU JAIN. "Denoising And Feature Extraction Of Ecg Using Discrete Wavelet Transform I". (2013),
- [13] CORNELIA, GORDAN, ; REIZ ROMULUS. "ECG signals processing using Wavelets." IEEE, proceedings of the fifth laserd International conference. (May. 2005),

- [14] CHRISTOV, IVAYLO, et al. "Rhythm Analysis by Heartbeat Classification in the Electrocardiogram." *International Journal Bioautomation* 13.2: (2009), 84-96.
- [15] INCE, TURKER, SERKAN KIRANYAZ, AND MONCEF GABBOUJ. "A generic and robust system for automated patient-specific classification of ECG signals." *Biomedical Engineering, IEEE Transactions on* 56.5: (2009), 1415-1426.
- [16] GARCÍA, A., et al. "Development of an algorithm for heartbeats detection and classification in Holter records based on temporal and morphological features." *Journal of Physics: Conference Series*. Vol. 332. No. 1. IOP Publishing. (2011),
- [17] VALENS, CLEMENS. "A really friendly guide to wavelets." ed. Clemens Valens(1999),.
- [18] GONZALEZ, R. C., & WOODS, R. E. *Digital Image Processing Third Edition*. Upper Saddle River, New Jersey: Pearson Education, Inc. (2008).
- [19] The Math Works, Inc. (2012). Fuzzy Logic Tool Box: Design and simulate fuzzy logic systems. Retrieved October 18, 2013, from MathWorks: <http://www.mathworks.com/products/datasheets/pdf/fuzzy-logic-toolbox.pdf>
- [20] CHIKH A., M., AMMAR, M., MAROUF, & RADJA, M. *A Neuro-Fuzzy Identification of ECG Beats*. Tlemcen, Algeria. (2010, April 5).
- [21] Jang, J.-S. R. *ANFIS: Adaptive-Network-Based Fuzzy Inference System*. *IEEE Transactions on Systems, Man, and Cybernetics*, VOL. 23, NO. 3. (1993).
- [22] SUMATHI, S., BEAULAH, H. L., & VANITHAMANI, R. A. *Wavelet Transform Based Feature Extraction and Classification of Cardiac Disorder*. New York: Springer Science + Business Media. (2014).
- [23] SMITH, LINDSAY I. "A tutorial on principal components analysis." *Cornell University, USA* 51: 52(2002),.
- [24] ABDI, HERVÉ, ; LYNNE J. WILLIAMS. "Principal component analysis." *Wiley Interdisciplinary Reviews: Computational Statistics* 2.4: (2010), 433-459.
- [25] <http://www.sosmath.com/matrix/eigen2/eigen2.html>.