

Resumen

El electrocardiograma (ECG) es una de las herramientas más utilizadas en la medicina, permitiendo al médico entender el funcionamiento del corazón humano y detectar distintas patologías. La detección temprana de arritmias y patologías es crucial en el tratamiento de un paciente y prevención de ataques cardíacos. Naturalmente, el procesamiento informático de ECGs para detección automática de patologías ha sido un área de interés en la comunidad científica, teniendo como objetivo el desarrollo de sistemas portátiles que puedan detectar problemas cardíacos en pacientes ambulatorios. Las ANNs han sido candidatas a solucionar este problema debido a sus propiedades en el reconocimiento de patrones, y el bajo costo de procesamiento que normalmente tienen. Esta monografía menciona de forma no-extensiva algunos de los trabajos realizados para implementar ANNs que reconozcan patologías cardíacas en tiempo real con sus alcances y limitaciones, por último se mencionan algunos de los problemas conocidos en el uso de ANNs para este problema, y alguna de las áreas dónde debe seguirse investigando.

1. Introducción




Figura 1 ECG y sus momentos característicos (M. D. Dale Dublin 2000)

Un electrocardiograma (ECG) es una grabación de la actividad eléctrica del corazón, obtenida mediante electrodos posicionados en el cuerpo. Un ECG contiene 5 momentos característicos marcados con letras consecutivas del alfabeto P, Q, R, S, y T. Las arritmias y otras patologías cardíacas pueden ser clasificadas por un médico en base a las características de estos momentos (M. D. Dale Dublin 2000). La detección temprana de arritmias es esencial para el tratamiento del paciente. Esto ha impulsado en las últimas décadas a una amplia investigación sobre el procesamiento informático de las señales de ECG para su reconocimiento automático y en tiempo real. Muchos

algoritmos distintos son enumerados en (Yu & Chou 2008), más adelante se discutirá un método propuesto en dicho artículo para clasificar arritmias utilizando redes neuronales para clasificar el complejo QRS.

Las redes neuronales artificiales (ANN por sus siglas en inglés) son modelos matemáticos que emulan a sus pares biológicos. Son frecuentemente utilizadas en tareas de reconocimiento de patrones debido a su capacidad de aproximar funciones de manera no lineal y su versatilidad de entrenamiento para tareas determinadas (Haykin 1998). Las ANN en general requieren poco costo de procesamiento, esto sumado a la capacidad de reconocer patrones las hace candidatas a resolver el problema de la detección automática de patologías cardíacas.

Muchos trabajos se han realizado sobre el reconocimiento de ECG usando ANN. Esta monografía hará un repaso sobre algunas de las implementaciones, escogidas ya sea por novedosas o por obtener resultados mejores que otras implementaciones. En la sección 2 se presentan trabajos dónde se utilizan ANN para el pre-procesado de señales de ECG, ya sea para acondicionamiento de la señal como para detección de momentos característicos. En la sección 3 se presentan trabajos dónde se utilizaron ANN en conjunto con otros métodos para la clasificación de señales. Finalmente en la sección 4 se discuten problemas conocidos del uso de ANN en reconocimiento de señales de ECG

2. Uso de ANN para pre-procesado de la señal.

En esta sección se verán dos usos de ANNs para el pre-procesado de señales anterior a su clasificación. En 2.1 se presenta el uso de ANNs para el filtrado de ruido en señales con muy bajo SNR, en 2.2 se presenta un artículo dónde se utiliza una ANN simple para reconocer la sub-onda P de un ECG.

2.1. Uso de red neuronal de Hopfield (HNN) para reconstrucción de señales con bajo SNR.

En el trabajo desarrollado por (Poungponsri & Yu 2009) se presenta una novedosa solución a un problema enfrentado habitualmente en el estudio de señales de ECG. Una señal típica de ECG tiene amplitudes del rango entre 10 μ V y 5 mV, lo cual las hace muy susceptibles a ruidos generados por el instrumento de medición o por otras señales eléctricas del cuerpo (Zhang et al. 2008). Normalmente el SNR es aumentado utilizando filtros pasabajos, (Poungponsri & Yu 2009) presentan la utilización de HNN como una posible solución.

Una HNN es una red recurrente de N neuronas donde todas están conectadas entre sí y se activan de manera asíncrona. Todas las neuronas funcionan como entrada y salida del sistema. La HNN es capaz de retener en memoria patrones mediante un entrenamiento y devolverlos ante la presentación de patrones sometidos a bajo SNR o con pérdida de información (Haykin 1998).

En el trabajo se construye una HNN y se le presenta para su entrenamiento una señal ECG de 30000 muestras "limpia". Luego de entrenada se le presenta otra señal ECG también de 30000 a la que se le aplica un ruido blanco tal que la SNR es igual a 0. El resultado a la salida de la HNN es una señal reconstruida con una SNR muy alta y similar a la original (figura 3).




Figura 3 Cotejo de la señal con ruido, la señal reconstruida, y la señal original.

dimensiones pequeñas pueden ser entrenadas para filtrar ruido y reconocer la forma en tiempo y espacio de estas sub-ondas, en lugar de filtrar el ECG entero.

2.2 Reconocimiento de la sub-onda P.

La sub-onda P corresponde a la despolarización atrial, lo que hace importante su estudio para conocer la electrofisiología atrial. La sub-onda P se caracteriza por su difícil reconocimiento automático, dado su amplitud pequeña, generalmente deformada por offsets y ruido, también su morfología es variante en el tiempo. En el tiempo tampoco tiene un comportamiento estable, ya que su distancia con el complejo QRS (de detección más sencilla) varía con el tiempo, además la onda P es acotada en el tiempo, cubriendo alrededor de 30 muestras en un muestreo de 200Hz (Sternickel 2002).

Sternickel introduce un perceptrón de capa oculta (HLN (Haykin 1998)) como solución al reconocimiento. Como paso previo se aplica al ECG una transformación DTW (Graps 1995), que lleva la señal a un espacio tiempo-frecuencia similar a un espectrograma. Los componentes en frecuencia son presentados a la entrada de la HLN para cada instante




Figura 4 HLN utilizado por Sternickel.

temporal, la salida de la HLN es una neurona que indica la probabilidad que en dicho instante se esté en presencia de la sub-onda P. A su vez los rangos de frecuencia donde se manifiestan los componentes de la sub-onda P son conocidos, por lo que distintos componentes de frecuencia se ponderan a la entrada de la HLN. El entrenamiento utilizado fue un algoritmo estándar de retroalimentación (Hush & Horne 1993).




Figura 5 Se muestran conjuntos de 2 gráficas apareadas. Las gráficas inferiores muestran señales ECG, las gráficas superiores muestran la salida de la HLN.. (Sternickel 2002)

presencia de la sub-onda P en el 92% de los casos probados (utilizando la base de datos MIT-BIH).

3. Uso de ANN para clasificación de latidos.

En esta sección se presentarán dos trabajos en los que se utilizan ANNs para la detección y clasificación de distintos tipos de arritmias. En 3.1 se presenta un artículo que utiliza un pre-procesado de la señal para obtener los IC (independent components) del complejo QRS para luego clasificar arritmias mediante una ANN. En 3.2 se presenta un artículo que plantea un novedoso método que consta de utilizar en conjunto distintas ANNs, cada una entrenada para ser experta en ciertos aspectos de ECG.

3.1 Uso de ICA para reconocimiento de arritmias por el complejo QRS.

“Independent component analysis” (ICA) es una técnica de procesamiento de señales que expresa un set variables aleatorias como la combinación lineal de variables estadísticamente independientes (Yu & Chou 2008). Su utilización para el estudio de señales de ECG fue introducida en (Owis et al. 2002) donde se aplica ICA a la transformada de Fourier de una señal de ECG para luego clasificar latidos. El estudio de Owis logró una sensibilidad de 100% para latidos normales, pero no fue capaz de clasificar correctamente, además Owis obtuvo estos resultados bajo la condición que 219 IC fueran considerados, lo cual implica un altísimo costo de procesamiento.




Figura 6 20 primeros IC del complejo QRS.

En el trabajo de (Yu & Chou 2008) se busca integrar los resultados obtenidos por Owis con la utilización de ANNs. En particular se buscó clasificar ocho tipos distintos de latidos (normal y 7 arritmias) utilizando una “back-propagation neural network” (BPNN(Jang et al. 1997)) y una “probabilistic neural network” (PNN (Specht 1990)). Ambas con bajo costo de procesamiento. Se esperaba que dadas las propiedades de reconocer patrones con poca información de las ANNs, poder clasificar de manera correcta los tipos de latidos utilizando un número reducidos de ICs. Los tipos de arritmias que se buscaban reconocer eran discernibles a partir del complejo QRS, por lo se estudió un entorno de este complejo y no el latido entero para la clasificación. La detección del complejo QRS no es trivial, pero existe una gran variedad de métodos, en (Rodríguez et al. 2015) se enumeran y desarrollan algunos de los métodos más efectivos.

El experimento desarrollado fue el siguiente, utilizando la base de datos de MIT-BIH se tomaron para el set de entrenamiento 4900 señales en un entorno del complejo QRS comprendiendo 200 muestras cada una. Estas señales fueron filtradas para eliminar el offset y normalizadas para no confundir categorías debido a la amplitud variable de las señales entre pacientes. A estas señales se les aplico ICA para obtener 23 IC para la BPNN y 33 para la PNN (determinados empíricamente). Estos IC se utilizaron como entrada de las ANNs. A otro set de 4900 señales se les aplicó el mismo procesado y se los presento a las ANNs para su reconocimiento. En la tabla 1 se presentan los resultados obtenidos. Para ambas ANNs se obtuvieron performances de reconocimiento mayores a 98% promediando las 8 categorías.

Tabla 1 Resultados(Yu & Chou 2008)

IC number		BPNN classifier		PNN classifier	
		Mean	Std	Mean	Std
Specificity (%)	NORM	99.650	0.106	99.906	0.061
	LBBB	96.250	1.658	99.650	0.122
	RBBB	99.150	0.673	99.975	0.075
	PVC	98.455	0.415	98.016	0.186
Sensitivity (%)	APB	98.403	0.475	98.508	0.537
	PB	99.375	0.464	100.000	0.000
	VFW	90.127	3.073	88.898	1.225
	VER	91.538	2.609	92.885	0.881
Accuracy (%)		98.367	0.235	98.710	0.082

3.2 Combinación de distintas redes para clasificación de ECG.

Por último se presenta el concepto de división de tareas en ANNs y combinación de resultados utilizando también ANNs. Cómo se ha mencionado en las partes anteriores, existen diversos tipos de ANNs aplicables al procesamiento o pre-procesado de señales de ECG para la detección de momento característicos y clasificación de arritmias. Diversos artículos han propuesto modelos que son más o menos expertos en el reconocimiento de ciertos tipos de arritmias o formas de onda, sin haber un único modelo experto en el reconocimiento de todas las secciones espaciales y temporales de la señal de ECG. De estas apreciaciones nace el concepto de ANNs combinadas para la clasificación, en (Woods et al. 1997) se discute este concepto y se nombran dos categorías principales de combinación: Fusión y

Selección. En la primera se utilizan varios modelos que se entrenan para clasificar la señal a lo largo de todo el espacio temporal, la segunda se implementa mediante ANNs “expertas” en ciertas secciones de la señal y que extraen información y/o clasifican la señal en base a estas secciones. Las salidas de las ANNs a su vez son presentadas a un clasificador global, que decide en base a estas a dónde categorizar finalmente la señal de entrada.

En (Wolpert 1992) se introduce un modelo llamado “Stacked Generalization Method” (SGM) para decidir sobre las clasificaciones de las ANNs “expertas”. Wolpert divide el problema en dos niveles usando una combinación de selección. En el nivel-0 están las ANNs “expertas”, que son HLN encargadas de reconocer distintas secciones temporales de la señal. En el nivel-0 se encuentra una HLN de mayores dimensiones encargada de discernir sobre las clasificaciones del nivel-0. El entrenamiento se realiza según métodos de entrenamiento habituales de ANN, las ANNs del nivel-0 aprenden a mapear entre la señal de entrada y las distintas categorías, mientras la ANN de nivel-1 aprende a mapear entre el nivel-0 y las categorías. Esta última ANN no tiene información sobre la señal de entrada. Los resultados de este método fueron prometedores, con una clasificación correcta en un 94% de los casos.

Este mismo modelo fue modificado años más tarde en (Javadi et al. 2011), en este trabajo la ANN de nivel-1 además de tener como entradas las salidas del nivel-0, se le agrega como entrada la señal original tanto para entrenamiento como para reconocimiento. Esto le permite al clasificador final conocer el mapeo entre la señal original y las ANNs “expertas”, de forma que pueda conocer los tipos de señales para los cuales cada ANN de nivel-0 tiene mejor o peor rendimiento, y cambiando la ponderación de las mismas en cada caso. Con esta modificación se logró alcanzar un reconocimiento correcto en el 95.2% de los casos.

Si bien los resultados obtenidos en ambos trabajos no alcanzan la precisión del trabajo presentado en 3.1, se considera que el método ofrece una mayor flexibilidad en la detección de patologías cardíacas. Cabe recordar que los “expertos” del estudio eran MLNs simples, estas pueden ser sustituidas por otras estructuras como las mencionadas en 2.2 y 3.1 para lograr un nivel-0 capaz de reconocer una gran cantidad de propiedades de la señal y clasificar distintas patologías, para luego ser combinados por el nivel-1.




Figura 7 Arriba se muestra la estructura del SGM, abajo la modificación realizada en el trabajo de Javadi. (Javadi et al. 2011)

4. Problemas conocidos y áreas para investigar.

Una de las grandes desventajas del uso de ANNs para clasificación de señales de ECG es la gran variabilidad que tienen las últimas ya sea entre distintos pacientes, o en un mismo paciente realizando distintas actividades (Mohamed et Al. 2011). Para lograr ANNs que cubran esta variabilidad deberían desarrollarse sets de entrenamiento gigantescos aplicables a cualquier paciente, o entrenamientos exhaustivos caso a caso. Ninguna de estas soluciones lleva al desarrollo de un sistema de detección automática realizable en la práctica, ya sea por costo de producción y mantenimiento, o por costo de procesamiento y memoria.

Una solución a este problema es el uso de sets de entrenamiento dinámicos (Mohamed et Al. 2011), en dicho trabajo se plantea un algoritmo de clasificación fijo (no una ANN) cuyo resultado depende de la señal de ECG de entrada y un set de señales de categoría conocidas. Este sistema implementa un algoritmo el cuál según propiedades actuales del ECG elige cuales de las señales del set pueden ser utilizadas para el cotejo y cuales no pueden aplicar al estado actual del paciente. Si bien el trabajo no utiliza ANNs para la clasificación final, el algoritmo de elección de señales podría ser utilizado para actualizar el entrenamiento de una ANN en forma periódica, no hay al momento muchos trabajos sobre el tema.

En (Liang et al. 2014) se describe un sistema completo de detección de arritmias utilizando un detector Holter implantado que envía señales a un Smartphone y las mismas son reconocidas mediante un modelo oculto de Markov HMM. El mismo utiliza un entrenamiento asistido, y puede personalizarse al paciente. Si bien es un sistema interesante, el entrenamiento personalizado supone un alto costo de mantenimiento.

Un candidato a eliminar estos problemas es la división de problemas y posterior combinación de ANNs descrita por (Woods et al. 1997; Javadi et al. 2011; Wolpert 1992), siguiendo este concepto es posible desarrollar distintas ANNs de bajo procesamiento encargadas de reconocer pequeñas cualidades específicas de una señal de ECG, disminuyendo la variabilidad entre pacientes y en un mismo paciente realizando distintas actividades.

5. Referencias.

- Al., M. et, 2011. Real-Time Automated Cardiac Health Monitoring by Combination of Active Learning and Adaptive Feature Selection. *Submitted for KSII Transactions on Internet and Information Systems*, 7(1), pp.1–15.
- Graps, A., 1995. Introduction to wavelets. *IEEE computational science & engineering*, 2(2), pp.50–61.
- Haykin, S., 1998. Neural Networks : *Convergence*, pp.1–16.
- Hush, D.R. & Horne, B.G., 1993. Progress in supervised neural networks. *IEEE Signal Processing Magazine*, 10(1).
- Jang, J.-S.R., Sun, C.-T. & Mizutani, E., 1997. *Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence*, Available at: http://www.amazon.com/Neuro-Fuzzy-Soft-Computing-Computational-Intelligence/dp/0132610663/ref=sr_1_1?s=books&ie=UTF8&qid=1344453390&sr=1-1&keywords=Neuro+Fuzzy+and+Soft+Computing.
- Javadi, M. et al., 2011. Improving ECG classification accuracy using an ensemble of neural network modules. *PLoS ONE*, 6(10).
- Liang, W. et al., 2014. A novel approach to ECG classification based upon two-layered HMMS in body sensor networks. *Sensors (Switzerland)*, 14(4), pp.5994–6011.
- Owis, M.I. et al., 2002. Study of features based on nonlinear dynamical modeling in ECG arrhythmia detection and classification. *IEEE Transactions on Biomedical Engineering*, 49(7), pp.733–736.
- Poungponsri, S. & Yu, X.-H.Y.X.-H., 2009. Electrocardiogram (ECG) signal modeling and noise reduction using wavelet neural networks. *2009 IEEE International Conference on Automation and Logistics*, 3(2), pp.345–348.
- Rodríguez, R. et al., 2015. Feature Extraction of Electrocardiogram Signals by Applying Adaptive Threshold and Principal Component Analysis. *Journal of Applied Research and Technology*, 13(2), pp.261–269. Available at: <http://linkinghub.elsevier.com/retrieve/pii/S1665642315000103>.
- Specht, D.F., 1990. Probabilistic neural networks. *Neural Networks*, 3(1), pp.109–118.
- Sternickel, K., 2002. Automatic pattern recognition in ECG time series. *Computer Methods and Programs in Biomedicine*, 68(2), pp.109–115.
- Wolpert, D.H., 1992. Stacked generalization. *Neural Networks*, 5(2), pp.241–259.
- Woods, K., Kegelmeyer Jr, W.P. & Bowyer, K., 1997. Combination of multiple classifiers using local accuracy estimates. *IEEE Transactions on Pattern Analysis and Machine* Available at: http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=588027&npapers://84ad8ee7-04da-4f17-be04-5ac17122ed48/Paper/p8459.
- Yu, S.N. & Chou, K.T., 2008. Integration of independent component analysis and neural networks for ECG beat classification. *Expert Systems with Applications*, 34(4), pp.2841–2846.
- Zhang, W., Ma, T. & Ge, L., 2008. Enhancement of ECG signals by multi-resolution sub-band filter. In *2nd International Conference on Bioinformatics and Biomedical Engineering, iCBBE 2008*. pp. 2123–2126.
- M. D. Dale Dubin, rapid interpretation of EKG's, 6th Edition, Cover Inc, USA, 2000.