

Procesamiento de la señal eléctrica del corazón, usando máquinas de aprendizaje

Processing of the electrical signal of heart, using machine learning

Luis E. Mendoza, MgSc^{1*}, Gendy Monroy Estrada, Ing¹, Aldo Pardo García, MgSc, PhD², José Gerardo Chacón, MgSc, PhD³, Miguel Vera, MgSc, PhD³, Julio Contreras-Velásquez, MgSc, PhD(c)³, Valmore Bermúdez, MD, MPH, MgSc, PhD⁴

¹Grupo de Investigación Ingeniería Biomédica de la Universidad de Pamplona (GIBUP). Facultad de Ingenierías y Arquitectura. Cúcuta, Colombia.
E-mail de correspondencia: luis.mendoza@unipamplona.edu.co.

²Grupo de Investigación en Automatización y Control, Universidad de Pamplona, Cúcuta, Colombia.

³Grupo de Investigación Altos Estudios de Frontera (ALEF), Universidad Simón Bolívar, Cúcuta, Colombia.

⁴Centro de Investigaciones Endocrino-Metabólicas "Dr. Félix Gómez" Facultad de Medicina. Universidad del Zulia, Venezuela.

Resumen

La presión arterial PA, es una variable biológica importante en el análisis del sistema cardíaco, que junto con la señal eléctrica del corazón o electrocardiográfica SECG, permiten conocer en cierta medida el comportamiento del sistema cardíaco del ser humano. Hoy en día existen pocos trabajos que muestran la relación entre las dos variables. Es artículo muestra que existe una relación entre la PA y SECG. Es decir que se puede encontrar los valores de PA usando SECG. Para el estudio, se tomaron muestras de SECG, a 22 pacientes, 18 sanos entre los 17-26 años y 4 con PA alterada de 50-78 años. Se utilizó el equipo Powerlab, se usaron electrodos para capturar la SECG, a través de la derivación DI, una vez obtenida las muestra, se estudió su composición, en especial las ondas R y las ondas T, tener las zonas de manera individual y buscar los valores de PA sistólica y diastólica, usando un sistema de inteligencia artificial como lo son las redes neuronales y máquinas de soporte vectorial. Para segmentar la SECG en su onda R, T y las porciones equivalentes a sístole y diástole, se utilizó transformada Wavelet. Los patrones encontrados fueron utilizados para entrenar las técnicas de inteligencia artificial. En este artículo se demostró que es posible hallar la PA de un paciente usando técnicas de inteligencia artificial, con un porcentaje total de acierto de 98,488 y 95.708 para sístole diástole respectivamente. Finalmente, los resultados se mostraron en tiempo real en aplicativo móvil en tiempo real.

Palabras clave: Presión arterial, Transformada wavelet, Redes neuronales, Máquinas de soporte vectorial, Electrocardiografía.

Abstract

Blood pressure PA is one of the most important factor in analyzing the cardiac system, along with the heart's electrical signal or electrocardiographic signal SECG biological variables, these variables allow know to some extent the performance of the human cardiac system. Today there are few studies that show the relationship between the two variables and that demonstrate the relationship between PA and SECG. It's paper shows that there a relationship between PA and SECG. This means that you can find the values of PA using the SECG. For this study, the sampling was carried SECG, 22 patients, 18 healthy between 17 and 26 years and 4 with altered PA 50 and 78, for this the Powerlab equipment was used, where electrodes were used signal to capture the heart through the DI, once obtained the sample signals, the composition of this was studied, especially R and T waves in order to have individual zones and find the values of systolic and diastolic blood pressure, using a system of artificial intelligence such as neural networks and support vector machines.

We used Wavelet Transform for segment the SECG in its R and T wave, and shows its equivalent in systole and diastole portions. These signals and found patterns were used as training the neural network and support vector machines, was used supervised learning. In this paper we showed that was possible to find the PA of a patient using neural networks and support vector machines with a total success rate of 98.488 to 95,708 for systole and diastole respectively. Finally, a mobile application is used to display the values of PA in real time.

Keywords: Blood pressure, wavelet transform, neural networks, support vector machines, Electrocardiography.

La presión arterial (PA) y la señal eléctrica del corazón (SECG), son dos de las variables más importantes en el sistema biológico de los seres humanos y además son signos vitales comunes, que permiten conocer el comportamiento en cierta medida el comportamiento del corazón^{1,2,3}. Por otro lado, el determinar una relación entre la SECG y la PA es un paso importante en la medición de dicha variable de manera automática con solo la SECG^{4,5,6}. La PA indica la fuerza con que la sangre es impulsada por el corazón, y como fluye por todo el sistema arterial. Esta se divide en dos secciones; sístole y diástole donde, sístole o contracción es donde la sangre contenida en la aurícula o el ventrículo es expulsada y Diástole o relajación es la fase en que la aurícula o el ventrículo se llenan de sangre^{7,8}. Por otro lado, la señal ECG representa la actividad eléctrica de las células del corazón. Este impulso produce la contracción rítmica del corazón, donde el comportamiento eléctrico del corazón, se representa por medio de los latidos^{7,8,9}.

Nosotros demostramos que se puede medir la PA a través de los patrones de la SECG, ya que en SECG se puede identificar sístole, que inicia desde el punto máximo de la onda R, al punto máximo de la onda T y diástole inicia del punto máximo de la onda T al punto máximo de la onda R, estos dos movimientos son fundamentales para hallar la presión sistólica y presión diastólica^{4,10,11}.

Diferentes trabajos han desarrollado herramientas para el estudio de estas señales fisiológicas, pero ninguno se ha centrado en hallar la PA con SECG. Durante los últimos años, la teoría de la información y la medicina se han unido dando origen a la telemedicina, provocando grandes cambios y aportes importantes en el área de la salud el cual permite ofrecer mejores condiciones y estilo de vida a los pacientes.

Para llevar a cabo dicha investigación, se adquiere la señal electrocardiográfica, por medio de un circuito de adquisición de forma física o un equipo especializado como el Powerlab, una vez obtenida esta señal se le aplica procesamiento por medio de la transformada Wavelet, se hace segmentación a la señal, extrayendo las partes de sístole y diástole de la señal ECG, se crea una base de datos, luego esta información es la entrada a un sistema de redes neuronales artificiales y máquinas de soporte vectorial, que parametrizan la señal, y finalmente se visualiza la presión arterial de un paciente cualquiera, en un dispositivo móvil, que contenga un sistema operativo con plataforma android.

Esta investigación surge, porque actualmente la Presión Arterial se encuentra entre las principales causas de demanda de servicios de Salud de la población adulta, necesitando que el paciente tenga un constante monitoreo de esta, provocando gran congestión de pacientes en los centros de salud, a la espera de la toma de su PA. La Figura 1, muestra como la circulación impacta en todo el cuerpo humano, y la buena

circulación está relacionada con la PA, es decir si se tiene una circulación adecuada se tiene una PA adecuada.

Este trabajo tiene un aporte de cómo usando técnicas de aprendizaje se puede calcular con un porcentaje cercano a 98%, la PA en sujetos usando SECG.

Antecedentes

Diferentes trabajos se han desarrollado en el área, es importante resaltar que se han usado técnicas inteligentes en el procesamiento de la SECG y técnicas estadísticas^{4,13,14,15}, y algunos trabajos han tratado de demostrar que existe relación entre presión arterial y la señal eléctrica del corazón^{16,4,10}, con resultados que permiten evidenciar la necesidad de mejorarlos y de utilizar otras técnicas matemáticas, que permitan corroborar de manera más eficiente la relación existente. Otros trabajos demuestran que es posible medir la PA usando ple-tismografía y así mismo diferentes autores muestran valores de PA, que evidencian que es susceptible a cambios en la postura, obesidad, sedentarismo y alteraciones en la señal ECG, lo que permite tener un claro panorama de que es posible medir la PA usando SECG^{17,18}. Otros trabajos permiten conocer y muestran relación entre el comportamiento o estado del sistema cardíaco y la SECG, es decir si el sistema cardíaco se altera, esto tiene una repercusión en dicha señal^{18,19,20} y como la PA está relacionada con la fuerza que hace el corazón, por ende, esta debe tener una relación con la SECG. Entonces, nosotros proponemos una metodología nueva de como extraer patrones y zonas de sístole y diástole en la SECG, y así mismo como usar estos segmentos para lograr tener valores cuantitativos de PA.

Metodología

La metodología consta de cinco etapas, en la Figura 2, se muestra un diagrama de dicha metodología.

A continuación, se explica cada una de las etapas.

Adquisición de la señal ECG

En esta etapa se realiza la adquisición de la señal Electrocardiográfica por medio del Powerlab, que es un sistema de adquisición de datos que comprende hardware y software, es de uso general en la fisiología humana, para registrar y analizar señales. El sistema consta de un dispositivo de entrada conectado a un ordenador, en este caso con sistema operativo Windows, mediante un cable USB y el software "Scope", que se suministra con el Powerlab y proporciona las funciones de registro y visualización de señales, esto a través de funciones con Figurables en el software dependiendo de las necesidades, se uso una frecuencia de muestreo de 2000 muestras por segundo, un tiempo de registro de 50 segundos y por sujeto se tomaron 5 muestras.

Base de datos

En este proyecto la base de datos va a estar conformada por; edad, sexo, presión arterial tomada manualmente y las señales ECG, siendo las señales la base para realizar todo el proyec-

to. Se tuvo en cuenta 11 hombres sanos, todos estudiantes y 11 mujeres de las cuales, cuatro eran personas mayores con alteración de su presión arterial y el restante sin problemas de presión arterial, los estudiantes estaban en un rango de edad entre los 17 y los 26 años y las personas mayores con alteración de 50 y 78 años de edad. La longitud de la SECG adquirida fue de 100 mil datos. Lo cual quiere decir que se tiene una base de datos de 100 mil datos en filas y 110 columnas. Finalmente es importante mencionar que el estudio fue acompañado por un especialista en cardiología.

Figura 1. Circulación sistema y pulmonar¹²





Figura 2. Diagrama de la metodología desarrollada en el proyecto



Extracción de patrones sistólicos y diastólicos

La transformada wavelet (TW) fue la base para la extracción de patrones ya que permite obtener en su análisis una resolución tiempo-frecuencia, esto permite ubicar de manera más precisa el inicio y final de segmentos usando el espacio tiempo-escala que en primera instancia genera la TW y de esta manera lograr la segmentación de las SECG y extraer las porciones que indican sístole y diástole en todos los registros electrocardiográficos de los sujetos.


Usaremos La representación matemática de la transformada wavelet discreta que se define en la ecuación 1,^{13,14}.

$$f(t) = \sum_k \sum_j C_j k \phi(t) + \sum_k \sum_j d_j k \psi(t) \quad (1)$$

El objetivo del procesamiento, en este caso fue identificar inicialmente los picos de las ondas R y las ondas T. Para poder realizar la selección de familias Wavelet, se hicieron pruebas con diferentes wavelets, hasta determinar las adecuadas, para este caso se seleccionó la wavelet "sym1", para lograr detectar la máxima amplitud de la onda R y una wavelet "sym7", para detectar la máxima amplitud de la onda T. Una vez identificados los picos de las ondas R y los picos de las ondas T, se extraen los segmentos que contengan la información del proceso de sístole y el de diástole.

En una ECG, el proceso de sístole se identifica desde la mitad de la máxima amplitud de la onda R hasta la máxima amplitud de la onda T, y el de diástole desde la mitad de la máxima amplitud de la onda T hasta la mitad de la máxima amplitud de la onda R siguiente. Tal como se observa en la Figura 3.


Figura 3. Señal ECG original, donde se muestra la parte de sístole, y la parte de diástole



Máquinas de aprendizaje

El objetivo de aplicar máquinas de aprendizaje, es conseguir la caracterización de la parte de sístole y diástole extraída de la SECG. Redes neuronales artificiales: La Figura 4, muestra una red neuronal probabilística, que consta de varias entradas, la capa oculta que es la encargada de realizar el proceso internamente y las capas de salida que muestran el resultado^{21,22}.

Figura 4. Red Neuronal Artificial multicapa con n neuronas de entrada, m neuronas en su capa oculta y una neurona de salida



Las neuronas de entradas se escalan en peso multiplicador, y estas entradas son ponderadas y luego sumadas, como se describe en la ecuación 2.

$$X \sum_{i=1}^N (W_i X_i) \quad (1)$$

Donde X es la entrada de la señal, W es el peso multiplicador, i es la entrada del canal, y N es el número total de entradas. En este trabajo la red neuronal se utilizó, para realizar un entrenamiento, y una clasificación. Se usaron dos redes neuronales (RN) una para sístole y otra para diástole. En el entrenamiento de las dos RN, se usaron, las porciones de la SECG de sístole y las mediciones reales de presión sistólica de cada paciente para la red de sístole, y porciones de la SECG de diástole y las mediciones reales de presión diastólica de cada paciente para la red de diástole.


Una vez entrenada las RN, se procedió validar, el sistema, la validación se realizó con porciones de sístole y diástoles que no fueron usadas durante el entrenamiento y porciones de señales sistólicas y diástole de pacientes que no fueron utilizados en el entrenamiento. Por otro lado, para corroborar que efectivamente existe una relación entre PA y SECG, se usó maquinas de soporte vectorial de minimos cuadrados o LS-SVM, con el mismo propósito que se usó las redes neuronales. En LS-SVM, se realizó el mismo procedimiento de entrenamiento y validación, es importante mencionar que esta técnica busca un hiperplano que separe las dos o más clases a estudiar, diferentes autores muestran que esta técnica es mucho más robusta en aplicaciones con datos biológicos que las redes neuronales^{23,24,25}.

Visualización en tiempo real de los datos

Este proceso se realizó con el fin de tener los resultados en tiempo real, y que a futuro se pueda generar sistemas portables que permitan realizar este tipo de procedimientos y emitir alertas de aumento o disminuciones de PA o alteraciones de SECG y que los expertos puedan conocer de manera rápida y en tiempo record estas alteraciones. Para lograr la visualización, se diseñó un aplicativo para dispositivos móviles Android en App inventor, el cual es un sistema fácil de usar, y adicionalmente logró visualizar los datos de PA, que es la variable de interés en este caso. En este aplicativo no se muestra la SECG, ya que esta parametrizado para solo mostrar indices de PA del sujeto en estudio.

sistema funciona de manera precisa, ubica sin equivocarse en todas las señales y en todas las porciones QRST, de forma exacta el pico de la onda T (asterisco rojo) y el pico de la onda R (asterisco rosado).

Figura 5. Señal ECG y posición pico de la onda R y pico la onda T



Una vez identificadas de manera correcta las ondas R y la onda T, se procede a realizar la segmentación, extraer los segmentos de sístole y los segmentos de diástole.

Las Figuras 6 y 7, muestra ejemplos de los segmentos de sístole y diástole de la señal ECG de un paciente, es importante mencionar que cada SECG tiene 50 segmentos de sístole y 50 segmentos de diástole, es decir que cada señal puede utilizarse 50 veces para realizar analisis con sus porciones relacionadas.

En el proceso de validación se determinó la eficiencia del sistema se halló el % de error, descrito en la Ecuación 2.

$$\% \text{ Error} = \left(\frac{\text{ValorRNA} - \text{Valor medido}}{\text{ValorRNA}} \right) * 100\% \quad (2)$$

En la Tabla 1, se muestran los resultados obtenidos tanto por el especialista como es el valor medido como el valor obtenido con redes neuronales (RN) y LS-SVM. Nótese como el porcentaje de error total, usando 24 mediciones y usando RN es de 2.028, y compradno los resultados usando LS-SVM es porcentaje promedio del error fue de 1.511.

A

continuación, se describen los resultados más importantes de este trabajo.

Como se mencionó se adquirieron 11 señales para 22 sujetos 5 por cada sujeto.

La Figura 5, muestras los resultados del algoritmo de ubicación de la onda R y la onda T, como se puede evidenciar el

Tabla 1. Porcentaje de error para Sístole

Valor Medido	Valor	Valor LS-SVM	% Error RN	% Error
	RN			LS-SVM
111	113	111	1.801	0
112	110	112	1.785	0
94	94	95	0	1.063
93	93	93	0	0
138	146	139	5.797	0.724
136	137	139	0.735	2.205
146	146	143	0	2.054
149	149	149	0	0
118	122	120	3.389	1.694
104	104	102	0	1.923
108	101	105	6.481	2.777
104	103	104	0.961	0
104	101	101	2.884	2.884
105	101	105	3.809	0
104	101	104	2.884	0
92	101	100	9.782	8.695
107	107	105	0	1.869
105	105	107	0	1.904
100	101	100	1	0
102	101	102	0.98	0
107	107	105	0	1.869
116	120	118	3.448	1.724
102	105	105	2.941	2.941
103	103	105	0	1.941
Total del porcentaje de error para Sístole			2.028	1.511

En la Tabla 2, se muestran los resultados obtenidos tanto por el especialista como es el valor medido como el valor obtenido con redes neuronales (RN) y LS-SVM. Nótese como el porcentaje de error total, usando 24 mediciones y usando RN es de 6.126, y comprando los resultados usando LS-SVM es porcentaje promedio del error fue de 4.292.

Tabla 2. Porcentaje de error para Diástole

Valor Medido	Valor RN	Valor LS-SVM	% Error RN	% Error LS-SVM
79	80	80	1.265	1.265
74	72	74	2.702	0
64	68	68	6.25	6.25
67	76	67	4.477	0
86	100	88	16.279	2.325
88	88	88	0	0
100	105	100	5	0
102	103	86	0.98	15.686
78	81	79	3.846	1.282
68	69	68	1.47	0
65	68	65	4.615	0
64	64	64	0	0
58	59	57	1.724	1.724
61	61	61	0	0
59	58	90	1.694	52.542
52	52	52	0	0
66	71	67	7.575	1.515
60	100	70	66.666	16.666
62	61	62	0	0
74	74	73	0	1.351
67	66	69	0	0
83	100	85	20.481	2.409
67	67	67	0	0
61	63	61	3.278	0
Total del porcentaje de error para Diástole			6.126	4.292

Es importante mencionar que este trabajo deja un gran reto por resolver y son los falsos positivos o falsos negativos, ya que el sistema en ocasiones mide PA altas, siendo tomadas por el especialista como bajas y viceversa, esto conlleva a desarrollar un trabajo futuro que permita corregir dichos parámetros, dándole más eficiencia al sistema o buscando la forma de alertar al especialista por la medición tomada, para que se realicen otras actividades que permitan corroborar los resultados.

Visualización móvil

La aplicación funciona bajo protocolo IP, y se llama por medio la dirección IP la base de datos, se usó un teléfono celular Samsung Galaxy Music.

La base de datos, es creada en un servidor local, una vez creada, en matlab se digita la función "querybuilder" en el comand Windows, y esta función comunica a matlab con la base de datos, y cualquier cambio que se realice en la base de datos se refleja en matlab, y el cambio que se realice en matlab se refleja en la base de datos. La interfaz gráfica de la aplicación móvil se observa en la Figura 8. Los valores de PA, se muestran una vez el paciente se ha registrado.

Conclusiones

Los resultados arrojados fueron muy impresionantes ya que mostraron que, si existe una relación entre PA y SECG, aunque se esperaba resultados de efectividad más altos, con los que se cuentan actualmente se puede concluir que es posible ajustar esta metodología y lograr aumentar la efectividad a un 99%, ya que por ahora la metodología presenta una efectividad promedio de 97.098%. Por otro lado, la transforma wavelet mostró, en su espacio tiempo-escala que es la forma más efectiva de ubicar sístole y diástole correspondiente a la señal electrocardiográfica, esto ya que con se probaron técnicas como derivada y envolvente, pero no presentaron resultados significativos, motivo por el cual no se incluyeron. Así mismo las técnicas de aprendizaje utilizados fueron un gran soporte al ahora de relacionar la PA con SECG, mostrando resultados importantes, aunque en las tablas mostradas en resultados se observa que es mejor LS-SVM que RN, ya que sus porcentajes de error fueron menores, aunque en los dos casos, se presentan resultados como falsos positivos y falsos negativos, motivo por el cual, es importante, poner atención a estos procedimientos, ya que es importante evitar estos procesos, RN presenta 2 falsos positivos y LS-SVM presenta 1 falso positivo. Finalmente, se recomienda, realizar otros estudios en cuanto a las zonas de sístole y diástole en la SECG, con el fin de buscar de ser posibles patrones mucho más significativos y que mejoren la efectividad del sistema y evite los falsos positivos.

Agradecimientos

Se agradece al Grupo de Investigación GIBUP (Grupo de Ingeniería Biomédica de la Universidad de Pamplona), por todo el apoyo en la toma de datos y toma de muestras.

1. Zong W, Mood GB, Mark RG. Reduction of false blood pressure alarms by use of electrocardiogram blood pressure relationships. *Computers in Cardiology*. 1999: 305-8.
2. Wong YM, Zhang YT. The Effects of Exercises on the Relationship between Pulse Transit Time and Arterial Blood Pressure. En: *Conference Complex IEEE Engineering in Medicine and Biology Society*. 2005;5:5576-8.
3. Liu Q, Yan BP, Yu CM, Zhang YT, Poon CC. Attenuation of systolic blood pressure and pulse transit time hysteresis during exercise and recovery in cardiovascular patients. *IEEE Transactions on Biomedical Engineering*. 2014;61(2):346-352.
4. Wu, TH, Pang GKH, Kwong EWY. Predicting systolic blood pressure using machine learning. En: *7th International Conference on Information and Automation for Sustainability*. IEEE; 2014:1-6.
5. Wong MY, Zhang YT. The correlation study on the relationship between pre-ejection period and arterial blood pressure. En: *5th International Summer School and Symposium Medical Devices and Biosensors*. 2008: 92-93.
6. Zhang Q, Shi Y, Teng D, Dinh A, Ko SB, Chen L, Basran J, Dal Bello-Haas V, Choi Y. Pulse transit time-based blood pressure estimation using hilbert-huang transform. *Conference Complex IEEE Engineering in Medicine and Biology Society*. 2009:1785-8. 2009. p. 1785-1788.
7. Liu J, Zhou Y. Design of a Novel Portable ECG Monitor for Heart Health. En: *Computational Intelligence and Design (ISCID)*, 2013 Sixth International Symposium on (Vol. 2). IEEE; 2013:257-60
8. Yu J, Jeon T, Jeon M. Heart beat detection method with estimation of regular intervals between ECG and blood pressure. En: *Computing in Cardiology 2014*. IEEE; 2014:561-64).
9. Kumar, S, Ayub S. Estimation of Blood Pressure by Using Electrocardiogram (ECG) and Photo-Plethysmogram (PPG). In *Communication Systems and Network Technologies (CSNT)*, 2015 Fifth International Conference. IEEE;2015:521-24.
10. Ma T, Zhang YT. Correlation Study on the Variabilities in Pulse Transit Time, Blood Pressure, and Heart Rate Recorded Simultaneously from Healthy Subjects. En: *Conference Complex IEEE Engineering in Medicine and Biology Society*. 2005;1:996-9.
11. Soo-Yeon J, Chen W, Ward K, Rickards C, Ryan K, Convertino V, Najarian K. Wavelet based analysis of physiological signals for prediction of severity of hemorrhagic shock. En: *International Conference Complex Medical Engineering ICME*, 2009. IEEE;2009:1-6.
12. Tresguerras J, Villanua M, Lopez A. *Anatomía y fisiología del cuerpo humano*. España: Mac Graw Hill; 2010.
13. Garg, A, Blaber A.P. Wavelet transform coherence based investigation of existence of relationship between the cardiovascular and postural control systems during orthostatic challenge. En: *Conference Complex Engineering in Medicine and Biology Society (EMBC)*. IEEE;2012:3588-91.
14. Wang Z, Lai L, Xiong D, Wu X. Study on predicting method for acute hypotensive episodes based on wavelet transform and support vector machine. En: *Bio-medical Engineering and Informatics (BMEI)*, 2010 3rd International Conference. IEEE;2010:1041-45.
15. IbÑez CR. *Telemedicina: Introducción, aplicación y principios de desarrollo*. CES Medicina. 2007;21(1):77-96.
16. Baselli G, Misani M, Cerutti S, Porta A, Dalla Vecchia L, Lucini D, Pagani M. Changing relationships between skin blood flow and arterial pressure in mild exercise and recovery. En: *Proceedings of the 23rd Annual International Conference. Engineering in Medicine and Biology Society*. IEEE;2001:534-36.
17. Zong W, Moody GB, Mark RG. Effects of vasoactive drugs on the relationship between ECG-pulse wave delay time and arterial blood pressure in ICU patients. *Computers in Cardiology*. IEEE; 1998:673-76.
18. Franchi D, Bedini R, Manfredini F, Berti S, Palagi G, Ghione S, Ripoli A. Blood pressure evaluation based on arterial pulse wave velocity. *Computers in Cardiology*. IEEE;2006:397-400.
19. Le TQ, Bukkapatnam STS, Sangasoongsong A, Komanduri R. Towards virtual instruments for cardiovascular healthcare: Real-time modeling of cardiovascular dynamics using ECG signals. En: *Automation Science and Engineering (CASE) Conference*. IEEE;2010 :903-10.
20. Yan Chen, Changyun Wen, Haitao Tang, Linda Xiuzhen Teng. The relationship between different pulse wave velocity and systolic/diastolic pressure. En: *3rd IEEE Conference Industrial Electronics and Applications ICIEA*. IEEE;2008:1185-90.
21. Keshan N, Parimi PV, Bichindaritz I. Machine learning for stress detection from ECG signals in automobile drivers. En: *Big Data International Conference*. IEEE;2015:2661-9.
22. German-Sallo, Z, Petru Maior, David L. Distributed Approximating Functional Wavelet based neural network in ECG signal processing. En: *Automation, Quality and Testing, Robotics*, 2006 International Conference. IEEE; 2006: 451-4.
23. Faziludeen S, Sabiq PV. ECG beat classification using wavelets and SVM. En: *Conference on Information & Communication Technologies (ICT)*. IEEE;2013:815-8.
24. Kohli N. Verma, NK, Roy, A. SVM based methods for arrhythmia classification in ECG. En: *International Conference on Computer and Communication Technology (ICCCCT)*. IEEE;2010:486-90.
25. Sharma S, Nagal D. Identification of QRS complexes in single-lead ECG Using LS-SVM. En: *Recent Advances and Innovations in Engineering (ICRAIE)*. IEEE; 2014:1-4.