


Evaluación de calidad de los ECG adquiridos mediante teléfonos móviles usando tres algoritmos de clasificación

Edgar Muñoz¹, Juan Narváez¹, Raúl Suquinagua¹, Fabian Astudillo² 

¹ Escuela de Electrónica y Telecomunicaciones, Universidad de Cuenca, Av. 12 de Abril & Agustín Cueva, Cuenca, Ecuador.

² Departamento de Ingeniería Eléctrica, Electrónica y Telecomunicaciones, Universidad de Cuenca, Av. 12 de Abril y Agustín Cueva, Cuenca, Ecuador.

Autor para correspondencia: fabian.astudillos@ucuenca.edu.ec

Fecha de recepción: 25 de agosto de 2017 - Fecha de aceptación: 29 de septiembre de 2017

RESUMEN

El desafío Computing in Cardiology 2011, propuso desarrollar un algoritmo eficiente para clasificar la calidad de los electrocardiogramas (ECG) registrados mediante teléfonos móviles, los ECGs se clasifican en aceptables e inaceptables. El presente trabajo, dentro del marco del proyecto final de la optativa de procesamiento de señales biomédicas, evalúa el desempeño de una combinación de varios parámetros propuestos durante la competencia y tres esquemas de clasificación: reglas lógicas, máquinas de soporte vectorial (SVM) y redes neuronales. Para el entrenamiento de la red neuronal se combina diferentes entradas, de acuerdo a los parámetros de clasificación y características relevantes de cada señal ECG, extraídas mediante autovalores. El mejor desempeño se obtuvo usando SVM con ciertos parámetros específicos, mientras que presentaron menores desempeños usando la red neuronal y las reglas lógicas.

Palabras clave: Calidad de ECGs, computing in cardiology, PhysioNet, teléfono móvil.

ABSTRACT

Computing in Cardiology 2011 proposed to develop an efficient algorithm to classify the quality of electrocardiograms (ECG) recorded by mobile phones; the ECGs are classified as acceptable and unacceptable. Within the framework of the final project of the optional Biomedical Signal Processing, the present work evaluates the performance of a combination of several parameters and proposed during the competition three classification schemes: Logic Rules, Vector Support Machines and Neural Network. For the training of the neural network different inputs are combined, according to the classification parameters and relevant characteristics of each ECG signal extracted through eigenvalues. The best performance was obtained using SVM with certain specific parameters, while using the multilayer neural network and logic rules presented smaller performances.

Keywords: Quality of ECGs, computing in cardiology, PhysioNet, mobile phone.

1. INTRODUCCIÓN

Las enfermedades cardiovasculares son la principal causa de muerte en todo el mundo. Debido a esto, se busca una forma de prevención y diagnóstico mediante teléfonos móviles, ya que estos tienen una tasa de penetración alta en la población mundial. La Unión Internacional de Telecomunicaciones (ITU) estimó que en el año 2010 había 5.3 mil millones de abonados móviles, esto equivale el 77% de la población mundial (ITU, 2017).

Los teléfonos celulares brindan una oportunidad para ampliar el alcance de la atención médica. Por esto, no es de extrañarse que la *salud móvil* se esté promocionando como el mayor avance en la

mejora de los sistemas de salud, esto debido a que proporciona una oportunidad para ampliar el alcance de la atención sanitaria (Lester, Gelmon, & Plummer, 2006). Sin embargo, para un diagnóstico preciso se debe desarrollar un control riguroso de la calidad y la eficiencia de las mediciones realizadas por el teléfono (Silva, Moody, & Celi, 2011).

El desafío que propuso el congreso *Computing in Cardiology* 2011, fue desarrollar un algoritmo eficiente y capaz de ejecutarse en tiempo real dentro de un teléfono móvil. El objetivo fue clasificar los electrocardiogramas (ECG) entre aceptables o inaceptables, con respecto a su calidad. En este desafío se presentaron numerosos trabajos, entre ellos el de Langley *et al.* (2011), el cual propuso un análisis de las características, tales como la línea plana, saturación, deriva de línea de base y amplitudes. Por otro lado, el trabajo de Chudáček, Zach, Kužílek, Spilka, & Lhotská (2011) se basa en ciertas reglas que sirven para clasificar la calidad de los ECGs, entre estas reglas se encuentran la verificación de los contactos de los electrodos y el nivel de ruido.

Dentro del marco del proyecto final de la optativa de Procesamiento de Señales Biomédicas, el presente trabajo evalúa el desempeño de una combinación de los parámetros propuestos por Langley *et al.* (2011) y Chudáček *et al.* (2011), y su implementación en tres esquemas de clasificación.

2. MATERIALES Y MÉTODOS

2.1. Diagrama de bloques

En la Figura 1 se muestra los tres esquemas de clasificación considerados. El primer esquema realiza la clasificación evaluando los parámetros de los algoritmos de Langley *et al.* (2011) y Chudáček *et al.* (2011). El segundo esquema utiliza Máquinas de soporte Vectorial (SVM) y una red neuronal.

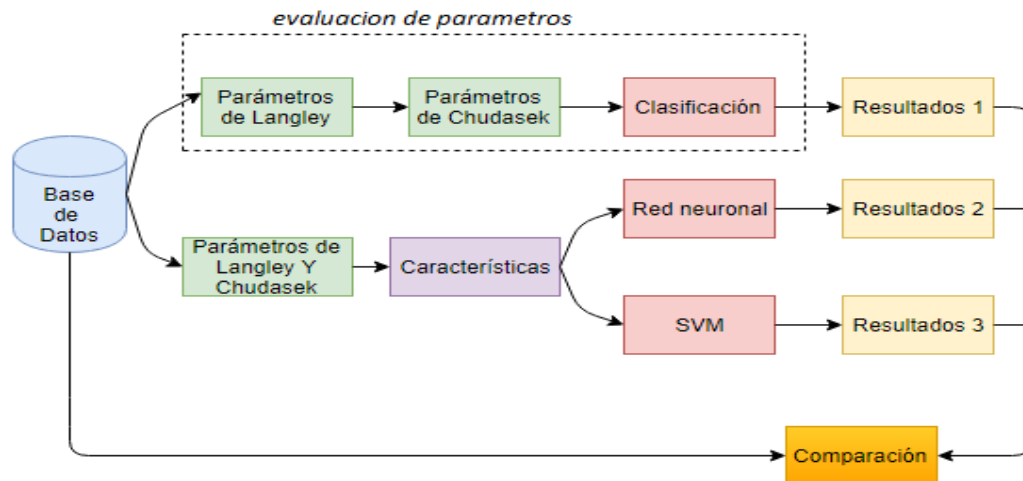


Figura 1. Diagrama de bloques de la metodología implementada en este trabajo.

Clasificación mediante la evaluación de parámetros

En esta etapa, las señales ECG son evaluadas con los seis parámetros del algoritmo de Langley *et al.* (2011). Luego, de manera secuencial, se analizan dos parámetros del algoritmo de Chudáček *et al.* (2011), la verificación de los contactos (electrodos) y el nivel de ruido. El algoritmo propuesto considera dichos parámetros viables para una mejora de la sensibilidad y especificidad de las señales ECG. Cada parámetro clasifica la señal como *aceptable* o *inaceptable*, es decir, si los ocho parámetros del algoritmo indican *aceptable* entonces la señal ECG se considera de buena calidad. Los parámetros son descritos a continuación.

- *Etapa 1:* En esta etapa se evalúa el parámetro de línea plana. Primero se define la frecuencia de muestreo del trabajo, que es $f_s = 500$ Hz, luego se crea un contador inicializado en cero, se define el tiempo T, el cual indica que el proceso empezará a los T segundos de la señal. Para

realizar el análisis se tomó un $T = 2$ segundos, debido a la restricción del método, se iniciará a $(2f_s + 1)$ muestras. Luego, mediante un bucle 'for' se recorre toda la señal para realizar la comparación de la muestra i con la muestra $i + 1$, si son iguales el contador incrementa, caso contrario se reinicia a cero. Si el contador llega a 500, lo cual corresponde a un segundo, la señal se clasifica como *inacceptable*.

- *Etapa 2:* En esta etapa se evalúa el parámetro de saturación. Se reinicia el contador en cero. La relación de voltaje de 1 mV corresponde a una muestra de amplitud 400, esto se determina según los valores de la base de datos. Para una amplitud de 2 mV se tendrá un valor de amplitud de muestra de 800. Se recorre toda la señal mediante un bucle 'for', en cada iteración se realiza la comparación; si la muestra es mayor a 800 entonces el contador incrementa en saltos de uno. Si el contador llega a 100, que equivale a 2 ms, se clasifica como *inacceptable*.
- *Etapa 3:* Esta etapa consiste en determinar la deriva de línea de base. Por lo que se fija una frecuencia de corte f_c , luego se define un filtro de sexto orden, se crea los parámetros del filtro mediante la función $butter(orden, f_c/(f_s/2))$. Se realiza el filtrado de la señal mediante la función $filter(b, a, señal)$ donde b, a son los parámetros de amplitud y fase respectivamente, que provee el filtro Butter. La señal filtrada es recorrida mediante un bucle desde los T segundos, en cada iteración se verifica si la amplitud de la muestra es mayor a 1000, que corresponde a 2.5 mV, entonces se clasifica como *inacceptable*.
- *Etapa 4:* Baja amplitud (LA): Se comprueba la amplitud del ECG en cada derivación. Si se encuentra cualquier derivación cuya amplitud máxima descienda por debajo del umbral de 125 μV , o al menos tres conductores se encuentren con una amplitud máxima por debajo de 175 μV . Es decir, si estas condiciones son ciertas, entonces se considera la etapa *inacceptable*.
- *Etapa 5:* Alta amplitud (HA): Si se encuentra alguna derivación cuya amplitud esté por encima de un umbral de 3.75 mV, entonces se verifica la amplitud alta en cada derivación. En esta etapa se determina HA mediante la obtención del valor máximo de cada derivación, si supera dicho umbral, la grabación se clasificará como *inacceptable*.
- *Etapa 6:* Inclinación pronunciada: Se determina si existe el ruido de alta frecuencia en los cables de ECG. Se analiza cada cable buscando cualquiera muestra cuya pendiente sea más pronunciada en un umbral de 250 $\mu V/muestra$. Si se encuentra algún cable con esta característica, el ECG se clasifica como *inacceptable*.
- *Etapa 7 (Regla 3 de Chudasek):* Esta regla evalúa si un ECG tiene picos muy grandes. Se implementa mediante el establecimiento de un umbral típico de las señales, posteriormente se evalúa si el valor máximo de una señal evaluada sobrepasa el umbral, esta es considerada como *inacceptable*.
- *Etapa 8 (Regla 5 de Chudasek):* Esta regla determina si el ECG tiene ruido. Se implementa un filtro *pasa altos* para obtener los componentes de alta frecuencia de la señal. La frecuencia de corte del filtro se define en 60 Hz. En el proceso de evaluación, se establece un umbral de amplitud para determinar si existe algún componente significativo de alta frecuencia, si algún componente de alta frecuencia sobrepasa el umbral, esta señal es considerada como *inacceptable*.

Extracción de características relevantes de la señal ECG

El objetivo principal es transformar un espacio en otro con diferente dimensión (más pequeña), y en la que sus datos no estén correlacionados. Esta característica proporciona información en la que se pueda diferenciar claramente unas señales de otras. Esto no es más que realizar una transformación utilizando autovalores y escoger los valores más relevantes del espacio muestral. Para el entrenamiento de la red neuronal se escogieron 12 valores.

Red neuronal

La señal ECG tiene un tiempo de duración de 10 segundos y tiene una frecuencia de muestreo de 500 Hz, por lo tanto, la señal ECG cuenta con 5,000 muestras. Esta dimensión presenta inconvenientes en el rendimiento de la red neuronal, por lo que se propone entrenarla con los 8 parámetros obtenidos

anteriormente de Langley *et al.* (2011) y Chudáček *et al.* (2011), junto con 12 valores obtenidos en la extracción de las características relevantes de la señal ECG.

En total se obtuvieron 20 parámetros para entrenar la red. Existen ciertos parámetros que no están correlacionados entre sí, lo cual afecta en el desempeño de la red neuronal. Para solucionar esto, se tomó una combinación de los 20 parámetros. En la Tabla 1 se muestra, con colores, los parámetros que se han combinado manteniendo más del 50% del número de parámetros. Se ha determinado el valor de la correlación de cada combinación. Los parámetros de la combinación con una fuerza de *moderada* y *fuerte* serán los parámetros de entrada de la red.

Tabla 1. Combinaciones y correlación de los parámetros.

ID	Parametros Langley						Chudacek		EigenValores												# Param.	Correlacion	fuerza			
	FB	SA	BD	LA	HA	Ss	R3	R5	1	2	3	4	5	6	7	8	9	10	11	12						
1																							20	0.12	Muy debil	
2																								11	0.44	Moderada
3																								14	0.82	Fuerte
4																								18	0.33	Debil
5																								12	0.71	Fuerte
6																								14	0.26	Debil
7																								12	0.68	Fuerte
8																								11	0.53	Moderada
9																								17	0.2	Debil
10																								10	0.43	Moderada

Máquina de Soporte Vectorial

Se aplica una red neuronal con un vector de aprendizaje supervisado, con un *kernel* de tipo *puk*, para las diferentes combinaciones de entradas con fuerza *moderada* y *fuerte*, como se muestra en la Tabla 1.

Base de datos

La base de datos del desafío *Computing in Cardiology 2011*, está compuesta por 1,000 registros ECG de 12 derivaciones cada una, con una duración de 10 segundos, frecuencia de muestreo de 500Hz y 16 bits de resolución. Cada registro tiene su respectiva anotación como *acceptable* o *inacceptable*. En base al trabajo de Pino, Gómez, & Martínez (2001), para el entrenamiento de los métodos de clasificación (RNA y SVM) se tomó el 80% de los registros de la base de datos, el porcentaje restante fue utilizado para pruebas.

Comparación

Secuencialmente se comparan las anotaciones (que provee la base de datos) con los resultados obtenidos de los tres diferentes métodos de clasificación (sin red Neuronal, SVM, y perceptrón multicapa) para obtener el desempeño de cada método.

2.2. Métricas de desempeño

Los resultados se los compara con las anotaciones para evaluar su desempeño, las cuales están basados en los indicadores: verdaderos positivos (VP), verdaderos negativos (VN), falsos positivos (FP), falsos negativos (FN). Con estos indicadores podemos expresar las medidas de desempeño, de la siguiente manera:

○ Sensibilidad:
$$SEN = \frac{VP}{VP + FN} \tag{1}$$

○ Especificidad:
$$ESP = \frac{VN}{VN + FP} \tag{2}$$

3. RESULTADOS

En la Tabla 2 se muestran los resultados de sensibilidad y especificidad, utilizando redes neuronales y máquinas de soporte vectorial, tomando como entradas las combinaciones *fuertes* y *moderadas* de la Tabla 1. Además, se puede observar que los mejores resultados son el ID = 3 e ID = 5, para máquina de soporte vectorial y redes neuronales respectivamente.

En la Tabla 1 se aprecia que el ID = 3 cuenta con 14 parámetros evaluados y el ID = 5 cuenta con 12 parámetros, es decir, no es necesario evaluar todos los parámetros para obtener el mejor resultado, eso se debe a que se realizó el análisis de todos los parámetros más importantes que resaltan los autores en Chudáček *et al.* (2011). La Tabla 3 muestra los resultados de evaluar mediante parámetros de Langley *et al.* (2011) y Chudáček *et al.* (2011), sin aplicar ningún tipo de red neuronal.

Tabla 2. Análisis de los mejores resultados con SVM y con Red Neuronal.

ID	SVM		Red Neuronal	
	Sensibilidad %	Especificidad %	Sensibilidad %	Especificidad %
2	75	70	71	70
3	90	87	77	68
5	81	78	87	88
7	82	80	76	77
8	83	81	76	79
10	77	71	54	53

Tabla 3. Resultados de evaluación mediante los parámetros de Langley *et al.* (2011) y Chudáček *et al.* (2011).

	Sensibilidad %	Especificidad %
Parámetros sin red neuronal	93	86

La Tabla 4 muestra los resultados obtenidos al evaluar una máquina de soporte vectorial con diferentes tipos de *kernel*, tomando como entradas los parámetros de ID = 3 (ver Tabla 1). Como se observa el mejor *kernel* es el de tipo *Puk*, obteniendo valores de sensibilidad de 94.2% y una especificidad de 87.01%.

Tabla 4. Resultados de la clasificación mediante la máquina de soporte vectorial.

Kernel	Parámetro C	Sensibilidad %	Especificidad %
Polykernel	0.2	86.16	86.95
Puk	0.3	94.2	87.01
RBF kernel	0.6	88.12	85.16

La Tabla 5 muestran los resultados obtenidos de la evaluación de una red neuronal de tipo perceptrón multicapa, con diferentes capas y tasas de aprendizaje, tomando como entrada los parámetros de ID = 5 (Tabla 1). Como se observa, el mejor resultado es con una tasa de aprendizaje igual a 0.72 con 38 capas, obteniendo un valor de sensibilidad de 87% y una especificidad de 88%.

Tabla 5. Resultados de la clasificación mediante el perceptrón multicapa.

Tasa de aprendizaje	Número de capas	Momento	Sensibilidad %	Especificidad %
0.08	15	0.2	79.52	81.16
0.3	20	0.2	82.14	86.16
0.72	38	0.2	87	87.99

4. CONCLUSIONES

Los parámetros de discriminación implementados en las diferentes etapas son, en cierta medida, simples, pero su aporte permite saber la calidad de la señal, ya que esta disminuye por diferentes factores como es el caso de malas conexiones de las derivaciones, cables defectuosos y más. Se han propuesto seis parámetros de Langley *et al.* (2011), dos de Chudáček *et al.* (2011) y doce autovalores, los cuales son parámetros de entrada para obtener diferentes resultados y obtener el mejor. Se obtuvo el mejor resultado mediante la evaluación de catorce parámetros, usando máquinas de soporte vectorial. Esto dio como resultado una sensibilidad de 94.2 y una especificidad de 87.01. Según Langley *et al.* (2011) y Chudáček *et al.* (2011), estos valores son aceptables. Mediante la Tabla 2 se puede determinar que tanto una red neuronal como un SVM tienen mejor desempeño cuando sus parámetros de entrada tienen un alto grado de correlación.

AGRADECIMIENTOS

A Sara Wong, docente del Departamento de Eléctrica, Electrónica y Telecomunicaciones de la Universidad de Cuenca, quien asesoró con la evaluación de este proyecto.

REFERENCIAS

- Chudáček, V., Zach, L., Kužílek, J., Spilka, J., Lhotská, L. (2011). Simple scoring system for ECG quality assessment on Android platform. *2011 Computing in Cardiology*, 38, 449-451.
- ITU. (2017). *World Telecommunication/ICT Indicators database*. Recuperado el 15 de marzo de 2018, a partir de <https://www.itu.int/en/ITU-D/Statistics/Pages/publications/wtid.aspx>
- Langley, P., Marco, L. Y. D., King, S., Duncan, D., Maria, C. D., Duan, W., ... Murray, A. (2011). An algorithm for assessment of quality of ECGs acquired via mobile telephones. *2011 Computing in Cardiology*, 38, 281-284.
- Lester, R., Gelmon, L., Plummer, F. (2006). Cell phones: tightening the communication gap in resource-limited antiretroviral programs? *AIDS*, 20(17), 2242-2244.
<https://doi.org/10.1097/QAD.0b013e3280108508>
- Pino, R., Gómez, A., Martínez, N. (2001). *Introducción a la inteligencia artificial: sistemas expertos, redes neuronales artificiales y computación evolutiva*. (1ª ed.). 106 p. Gijón, España: Servicio de Publicaciones de la Universidad de Oviedo.
- Silva, I., Moody, G. B., Celi, L. (2011). Improving the quality of ECGs collected using mobile phones: The PhysioNet/Computing in Cardiology Challenge 2011. *2011 Computing in Cardiology*, 38, 273-276.