

Ischemic and non-ischemic heartbeat classifier for portable automatic detection systems

Gisela De La Fuente-Cortes, *Member, IEEE*, A. Diaz-Mendez, *Senior Member, IEEE*, Guillermo Espinosa-FloresVerdad, *Member, IEEE*, and Victor R. Gonzalez-Diaz, *Member, IEEE*

Abstract—This article presents a new heartbeat classifier oriented to an automatic cardiac ischemia detection system aimed at the medical control of the population with cardiac disorders (a higher risk group of severe COVID-19). The algorithm focuses on distinguishing ischemic heartbeats from non-ischemic based on methods and techniques proposed by medical experts in cardiac ischemia diagnoses. The proposed algorithm was tested with 80 electrocardiogram recordings obtained from the Long-term ST database of Physionet with a 100,112 heartbeat population. The heartbeat population contains different types of non-ischemic cases. The algorithm exhibits a sensitivity of 98.7 percent and specificity of 97.23 percent. The digital synthesis, in a 180nm CMOS process with a dynamic power consumption of 13.15 micro Watt demanding an area of 490x400 micrometers, attests to the algorithm benefits.

Index Terms—ASIC, Cardiac Ischemic, Fuzzy Logic.

I. INTRODUCCIÓN

Según la información publicada por la Organización Mundial de la Salud (OMS), la incidencia del virus SARS-CoV-2 durante la pandemia mundial de enfermedad por coronavirus COVID-19, muestra que la población con enfermedades crónicas, presenta más riesgos. Esto se agudiza en pacientes con condiciones médicas poco controladas. El control médico apropiado para una enfermedad crónica considera el diagnóstico oportuno y el control de los medicamentos del paciente. Dentro de las enfermedades preexistentes de riesgo para la enfermedad provocada por el SARS-CoV-2 se encuentra la isquemia cardíaca. Desafortunadamente, la isquemia cardíaca se diagnostica cuando ya está muy avanzada. Por lo que, una gran parte de la población del planeta no es consciente de su condición médica. Esta condición se presenta cuando existe un grado de oclusión en las arterias coronarias provocando que el suministro de oxígeno a los músculos del corazón sea ineficiente. Generalmente, cuando se presenta una infección COVID-19, el daño que se produce en el sistema respiratorio, dificulta el funcionamiento del corazón. Si aunado a esto, existe una cardiopatía isquémica no controlada la ocurrencia de un infarto súbito es altamente probable. Además, en los últimos 15 años, la cardiopatía isquémica ha sido la primera causa de mortalidad en el mundo, responsable de más de 9 millones de muertes en

2016. En este contexto, este tipo de enfermedades exigen sistemas automatizados móviles para el diagnóstico médico oportuno de alta precisión y que sean capaces de asignar niveles de riesgo para tomar cualquier medida. En la actualidad, existen dispositivos médicos electrónicos orientados a enfermedades cardíacas, que ayudan a preservar la vida del paciente durante períodos prolongados [1]. Aunque estos dispositivos electrónicos médicos controlan o restauran el ritmo cardíaco, no diagnostican ni tratan la oclusión en las arterias coronarias. El tratamiento para disolver y prevenir el trombo en la zona de oclusión aguda utiliza agentes químicos. Sin embargo, muchos de los tratamientos se llevan a cabo en salas de emergencia cuando ya se ha presentado un accidente cardiovascular y el daño en el corazón es irreversible. Esta es la principal razón por la que es necesario mejorar la detección automática de isquemia cardíaca y el tratamiento de microsistemas para la prevención y monitoreo continuo de la salud del corazón. Los recientes avances en dispositivos médicos cardíacos consideran la posibilidad de implementar un detector automático de isquemia cardíaca para contrarrestar la oclusión de las arterias, ya sea con una alerta a un dispositivo externo o mediante la liberación automática de medicamentos anti-isquémicos [2]–[5]. La señal del electrocardiograma (ECG) es la más utilizada en algoritmos de isquemia automatizados, debido a que es relativamente fácil de analizar y es posible detectar la isquemia cardíaca en las etapas iniciales. El latido del corazón es isquémico si muestra una desviación del segmento ST (elevación o depresión). Complementariamente, el “episodio isquémico” es un lapso de latidos isquémicos que dura más de 30 segundos. Desafortunadamente, existen otras afecciones cardíacas que producen las mismas desviaciones en el segmento ST, a estos cambios se les denomina eventos no isquémicos y su aparición dificulta una detección eficiente de la isquemia. Las propuestas recientes de detección de isquemia automática monitorean el diagrama de ECG con variables fisiológicas adicionales como presión arterial, saturación de oxígeno, frecuencia cardíaca, frecuencia respiratoria y hemodinámica para confirmar la isquemia [3], [4]. La principal limitación radica en la gran demanda de hardware [6] que imposibilita la movilidad del paciente y así su uso cotidiano. Por lo tanto, la tendencia clara es el desarrollo de los dispositivos portátiles que ayudan en la búsqueda de mejoras en el tamaño y la autonomía de un sistema de monitoreo en tiempo real [7]. La Fig. 1 muestra las etapas de detección automática de un detector de isquemia cardíaca genérico. La señal proviene de una conversión analógico-digital. La primera etapa filtra el ruido

A. Diaz-Mendez and Guillermo Espinosa-FloresVerdad are with the Department of Electronic, National Institute of Astrophysics, Optics and Electronic, Tonantzintla, Puebla, 72840 Mexico e-mail: ajdiaz@inaoep.mx, gespino@inaoep.mx

Victor R. Gonzalez-Diaz and Gisela De La Fuente-Cortes are with Faculty of Electronics, BUAP, Puebla, 72000 Mexico e-mail: vicrodolfo.gonzalez@correo.buap.mx

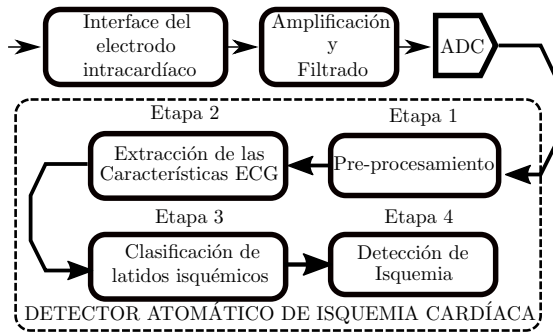


Fig. 1. Diagrama a bloques de un detector automático de isquemia

y realiza la corrección de la línea de base para obtener una secuencia ECG sin errores. La segunda etapa monitorea las curvas y puntos importantes del ECG. Finalmente, la tercera y cuarta etapas clasifican los eventos isquémicos al agrupar los latidos isquémicos en un lapso de tiempo. La clasificación de los latidos del corazón es uno de los bloques más críticos en la detección automática de isquemia y determina el rendimiento de los sistemas. En este trabajo se propone un algoritmo de clasificación de latidos isquémicos y no isquémicos en tiempo real totalmente integrado. Está diseñado para una base de datos de superficie de ECG que incluye eventos no isquémicos. El algoritmo se describió en VHDL y se sintetizó en un circuito integrado de aplicación específica (ASIC) con una tecnología CMOS 180 nm. El documento está organizado de la siguiente manera: la sección II describe el impacto de este trabajo en relación con la enfermedad por coronavirus COVID-19, la Sección III resume los clasificadores de latidos del corazón ECG isquémicos más importantes. La Sección IV describe el algoritmo propuesto y detalla el diseño de la lógica difusa para la implementación de ASIC. La sección V muestra los resultados y el rendimiento del algoritmo propuesto. Finalmente, la Sección VI discute los resultados y conclusiones.

II. ISQUEMIA CARDÍACA Y COVID-19

El brote actual de infección por el virus SARS-CoV-2 está encaminando a las autoridades sanitarias a replantear las estrategias de prevención, diagnóstico y control de padecimientos cardiovasculares en la población a nivel mundial. Durante la pandemia de enfermedad por coronavirus COVID-19, se ha evidenciado que la población con este tipo de desordenes, tiende a presentar una mala evolución de la infección. De acuerdo con lo publicado por la revista Journal of the American Medical Association (JAMA) y el informe del centro de control y prevención de enfermedades de China [8], se ha confirmado que las enfermedades cardiovasculares están fuertemente asociadas al incremento de la mortalidad por COVID-19 en un 10.5%. La cardiopatía isquémica se posiciona por debajo de la edad avanzada como el segundo factor de riesgo con un 30% del total de defunciones en países como Italia y China. Además existe evidencia que señala que la COVID-19 aumenta las probabilidades de mortandad en pacientes con problemas cardíacos mal controlados. La

Tabla I
COMPARACIÓN DEL RENDIMIENTO DE DETECTORES DE ISQUEMIA

Ref	Se %	Sp %	PPV %	Base de datos
[9]	94.4	93.4	86.9	European ST-T
[10]	98.56	99.76	99.4	European ST-T
[11]	98	98	-	90 patients
[12]	81	88.1	86.3	Long-Term ST Database
[13]	99	88.8	91.1	Long-Term ST Database
[14]	88.7	86.8	87.4	Long-Term ST Database
[15]	80-100	-	71-100	ESC ST-T
[16]	79.73	68	-	ESC ST-T

propuesta de un algoritmo para el desarrollo de sistemas portables como el presentado en este trabajo facilitaría el diagnóstico y control oportuno de isquemia cardíaca y permitiría la reducción del factor de riesgo de mortandad ante la exposición al virus SARS-CoV-2. Por otro lado, sería un auxiliar para el monitoreo de la salud cardíaca de la población que se recuperó de la enfermedad COVID-19 y que según recientes estudios quedarán con secuelas en el largo plazo.

III. CLASIFICADORES EXISTENTES DE LATIDOS ISQUÉMICOS Y NO ISQUÉMICOS.

En el estado del arte existen algunos grupos de investigación que consideran la clasificación de los latidos del corazón con una desviación del segmento ST [9]–[11], pero estos no consideran los latidos no isquémicos. Existen otros trabajos que si discriminan entre latidos isquémicos y no isquémicos, pero utilizan métodos muy demandantes [12]–[14]. La Tabla I muestra el rendimiento general de los sistemas de detección automática de isquemia y los diferentes métodos para implementar cada una. Con fines de referencia, es importante mencionar las métricas de rendimiento en la detección automática de isquemia y los algoritmos de clasificación de latidos. La mayoría de los algoritmos existentes utilizan la sensibilidad y la especificidad para medir el rendimiento del sistema. La sensibilidad (Se%) y la especificidad (Sp%) se definen como $Se\% = \frac{TP}{TP+FN}$, $Sp\% = \frac{TN}{TN+FP}$. Donde TP son los verdaderos positivos, FN son los falsos negativos, TN son los verdaderos negativos y FP son los falsos positivos. Aunque estas métricas se usan ampliamente, no reflejan el costo médico de los falsos positivos. Por esta razón, es preferible utilizar métricas de rendimiento adicionales como el valor predictivo positivo (VPP) y el valor predictivo negativo (VPN). $VPP\% = \frac{TP}{TP+FP}$, $VPN\% = \frac{TN}{TN+FN}$. Si los valores disminuyen, podemos interpretar que los casos de falsos positivos o falsos negativos aumentan. Este simple cambio mejora la detección del algoritmo para todas las circunstancias. Hasta ahora, no hay detectores automáticos comerciales de isquemia cardíaca en el mercado. Sin embargo, la Tabla I muestra una comparación del rendimiento alcanzado por algunas propuestas, que abordan el mejoramiento de una o varias etapas del sistema convencional. Por ejemplo, el algoritmo propuesto en [15], extrae las características del ECG sin la implementación de filtros. En cambio, utiliza un método digital conocido como descomposición del modo empírico, éste método elimina el desplazamiento de la línea de base del ECG.

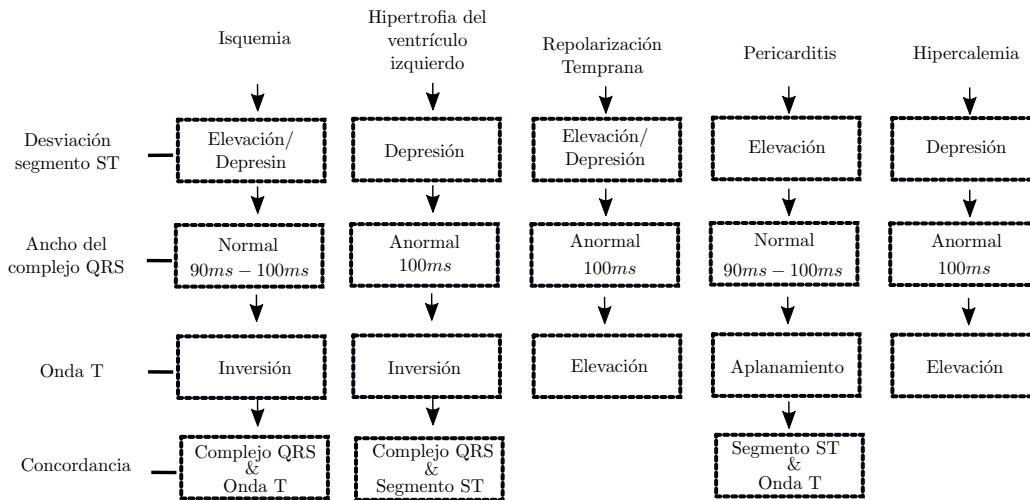


Fig. 2. Características importantes de la isquemia cardíaca y eventos no isquémicos

El trabajo mencionado reporta una precisión del 71 % a 100 %, dependiendo del paciente. Otros trabajos proponen nuevas etapas funcionales como el algoritmo propuesto en [16], que incluye una etapa adicional para predecir enfermedades de isquemia con el uso del Perceptrón multicapa y la Función de base radial. La sensibilidad y la especificidad de la detección de isquemia cardíaca son de 79.73 % y 63 %, respectivamente. En publicaciones como [9]–[11], la propuesta se enfoca en la etapa de clasificación y a pesar de poseer un rendimiento aceptable, utilizan una base de datos que no considera eventos no isquémicos. Por otra parte, existen propuestas dedicadas a la distinción entre latidos isquémicos y no isquémicos. Estos trabajos utilizan la base de datos “*Long-Term ST database de Physionet* [17].” A pesar del alto rendimiento que exhiben, su implementación demanda altos recursos de hardware, lo que imposibilita su implementación en sistemas portables de detección automática. Es posible advertir que los algoritmos que basan su clasificación en los cambios del segmento ST poseen una alta sensibilidad y una baja especificidad, como consecuencia de los falsos positivos provocados por los latidos no isquémicos. La distinción entre ambos latidos, es una tarea complicada; inclusive para los expertos más experimentados. En esta disciplina, existen propuestas que consideran la evaluación de otras características del ECG para una clasificación precisa. La Fig. 2 muestra un esquema con las principales características no isquémicas [18]–[20]. La inclusión de estas características permite aplicar un procedimiento médico conocido como diagnóstico diferencial, que consiste en determinar una enfermedad al excluir otras posibles causas. Este artículo propone un algoritmo de clasificación de latidos basado en este tipo de diagnóstico orientado a aplicaciones de baja potencia en un chip de aplicación específica ASIC.

IV. MÉTODO

La Fig. 2 relaciona algunos desordenes cardíacos con las desviaciones en el segmento ST, el ancho del complejo QRS,

los cambios en la onda T y la concordancia entre curvas. Una onda T negativa también es un indicativo de isquemia cardíaca. Sin embargo, esta morfología en la onda T está presente en otras enfermedades cardíacas como la hipertrofia ventricular izquierda. Es así, como se incluye en el proceso de identificación, al ancho del complejo QRS y la concordancia entre las curvas del ECG para mejorar la clasificación. La concordancia del ECG se define como la relación entre el signo del complejo QRS con otras curvas de ECG. Siguiendo el esquema de la Fig. 2, la concordancia entre el complejo QRS y la onda T es indicativa de isquemia, mientras que la concordancia entre el complejo QRS y el segmento ST es indicativa de hipertrofia ventricular izquierda. Además, la concordancia de la onda T con el segmento ST es indicativa de pericarditis. Por lo tanto, el método en este trabajo se basa en la siguiente observación: “*Si un latido del corazón tiene una desviación del segmento ST y una inversión de la onda T, podría clasificarse como un latido isquémico solo si el ancho del complejo QRS es normal y hay concordancia entre el complejo QRS y la onda T.*” El razonamiento anterior demanda que el algoritmo asemeje el razonamiento humano. Afortunadamente dentro del área de la Inteligencia Artificial, se halla la lógica difusa que permite el análisis de datos del mundo real en una escala de verdadero a falso emulando el comportamiento lógico de la razón humana. Este trabajo considera la implementación física de un sistema de lógica difusa digital. La Fig. 3 muestra el diagrama de bloques general del algoritmo de clasificación propuesto en este trabajo. La implementación digital usa un mínimo de 12 bit de resolución.

A. Etapa de pre-procesamiento (Etapa 1)

Esta etapa consta del filtrado de la señal del ECG digitalizada y la eliminación del desplazamiento de la línea de base, para esto se implementa una Transformación discreta de ondoleta o Wavelet (DWT) mediante un banco de filtros Wavelet (WFB). Este método es una herramienta útil para el

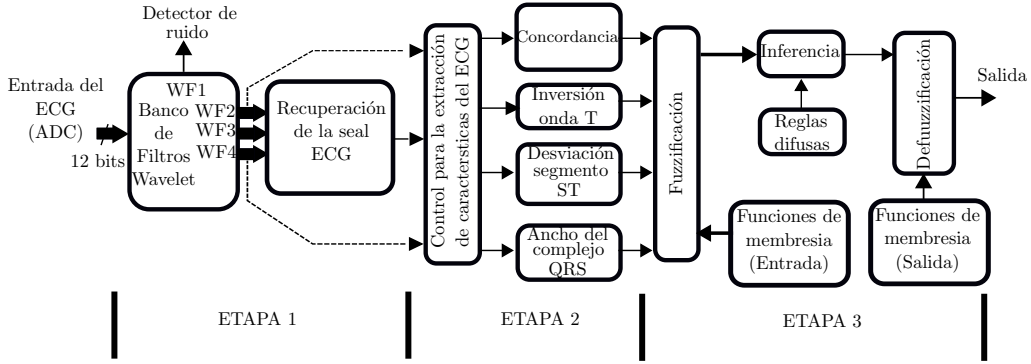


Fig. 3. Diagrama a bloques del algoritmo propuesto para la clasificación de latidos isquémicos.

Tabla II
FRECUENCIA Y DURACIÓN DE LAS CURVAS, SEGMENTOS E INTERVALOS DEL ECG.

Características ECG	Frecuencia (Hz)	Duración (ms)	Duración Ciclos de Reloj
Onda P	8-10	60-80	15-20
Intervalo PQ/PR	-	120-200	30-50
complejo QRS	10-40	80-120	20-30
Segmento ST	-	100-120	25-30
Onda T	5-8	120-160	30-40
Intervalo RR	-	600-1200	150-300

análisis de señales multi-resolución no estacionarias, permitiendo el análisis de señales en múltiples bandas de frecuencia. La señal del ECG se descompone en una familia de funciones al escalar y variar la frecuencia de una función base (la wavelet de Daubechies para este caso). El banco de filtros wavelet está compuesto por una estructura de filtros digitales pasa bajas y pasa altas conectados en cascada. El diseño de los filtros considera las especificaciones publicadas en [21]. El banco de filtros otorga 4 coeficientes (WF1, WF2, WF3 y WF4) que ingresan a un sistema basado en [21] para la reconstrucción de la señal (Multi-scaled Product). El sistema consiste en un detector de ruido que se activa mediante el bit más significativo del coeficiente WF1, cuando el ECG exhibe elementos de alta frecuencia. Mediante multiplexores controlados por el detector de ruido, los coeficientes correspondientes entran a una etapa de multiplicación con signo. Para $ND = 1$, se obtiene el producto entre WF3 y WF4, en caso contrario se obtiene el cuadrado del coeficiente WF2. Este algoritmo de multiplicación mejora la identificación de variaciones abruptas y no periódicas reforzando los picos Q, R, S. De acuerdo con [21], la implementación a nivel integrado es viable, ya que solo consta de dos multiplexores y un multiplicador (vea la Fig. 4).

B. Extracción de las características del ECG (Etapa 2)

Para la extracción de las características del ECG, es indispensable detectar el complejo QRS en la forma de onda. Esto demanda la implementación de circuitos con muchos

requerimientos, como bancos de filtros y umbrales adaptativos. El algoritmo Pan-Tompkins es una opción frecuente en esta tarea. En contraste, en este trabajo se propone utilizar el valor absoluto de la señal $ECG(x)$ recuperada por el bloque antecedente (Etapa 1 en la subsección anterior). La Fig. 5 muestra la señal $ECG(x)$ recuperada y el valor absoluto de la misma $|ECG(x)|$. La posición de las curvas y puntos de interés (x) se detecta mediante $|ECG(x)|$, pero la evaluación se realiza en el $ECG(x)$. El ancho del complejo QRS se obtiene midiendo el número de ciclos de reloj que transcurren entre el punto inicial de Q (η_{l1}) y el punto final de S (η_{l2}). La Fig. 5 también muestra un acercamiento a la señal $|ECG(x)|$ donde se pueden observar las posiciones del pico R (η_R) y el pico T (η_{t1} , η_{t2} y η_T respectivamente). La desviación del segmento ST según [22] es:

$$PRp = \eta_R - \frac{\eta_{l2} - \eta_{l1}}{2} \quad (1)$$

$$STp = \eta_T - \frac{\eta_{t2} - \eta_{t1}}{2} \quad (2)$$

$$STdeviation = |ECG(PRp) - ECG(STp)| \quad (3)$$

Dónde $ECG(x)$ es la amplitud del ECG en el punto x . La ecuación (3) determina el grado de desviación del segmento ST y el bit más significativo (MSB) de $ECG(STp)$ proporciona el signo. De manera similar, el MSB en $ECG(\eta_T)$ detecta si existe inversión de la curva T. Con estos datos se determina la concordancia entre las curvas. La máquina de estados que se observa en la Fig. 4, es el bloque de control para la localización de puntos y la extracción de las características del ECG. Cada estado puede controlar tres bloques genéricos que detectan los puntos máximos, puntos iniciales y puntos finales de las curvas de interés en la señal $|ECG(x)|$. El pico de una curva se identifica mediante la comparación de $|ECG(x)|$ y $|ECG(x-1)|$ en un intervalo de tiempo, la posición del valor más alto se guarda en un registro externo. Por otro lado, la detección del punto final de una curva utiliza la posición del pico de la curva y a partir del mismo compara los siguientes $|ECG(x)|$ con $|ECG(x-1)|$ durante determinados ciclos de reloj, registrando la posición de valor mínimo. En cambio, para el punto inicial, primero se identifica el pico de la curva y se evalúan los puntos anteriores al mismo por un lapso de tiempo determinado por

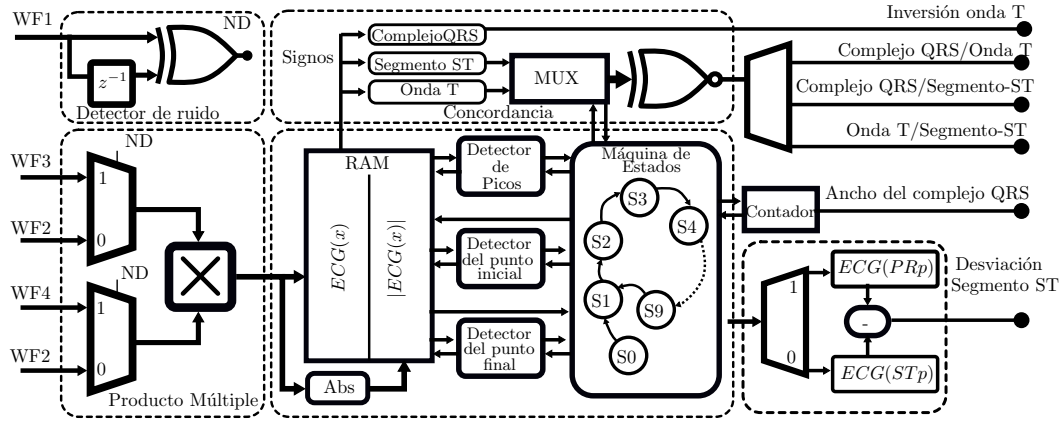


Fig. 4. Diagrama del algoritmo propuesto para la extracción de las características del ECG.

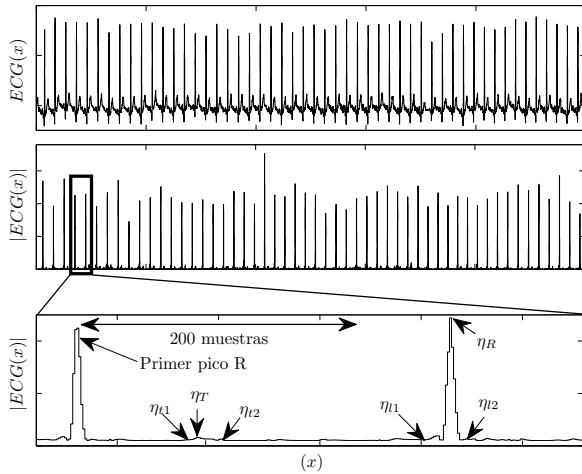


Fig. 5. Señal ECG recuperada $ECG(x)$, valor absoluto $|ECG(x)|$ y localización de los puntos de interés (η_{t1} , η_{t2} , η_R , η_{t1} , η_{t2} and η_T).

el tipo de curva (Ver Tabla II), registrando también el valor mínimo. La Tabla II muestra la frecuencia y la duración de algunas curvas del ECG. El número de ciclos transcurridos del reloj principal cuantifica la duración del tiempo de las funciones de ECG en el sistema propuesto. Estos tiempos se utilizan para la identificación aproximada de los puntos.

La memoria RAM está formada por dos bancos de memoria con 300 registros de 12 bit. Los bancos de la memoria RAM almacenan provisionalmente hasta 300 muestras de las señales $ECG(x)$ y $|ECG(x)|$. El algoritmo propuesto funciona de la siguiente manera. El estado S0 tiene como objetivo detectar el primer pico R de la señal $|ECG(x)|$, se dejan pasar 200 muestras, al finalizar se comienzan a guardar las señales en la RAM. En el estado S1 se detecta el pico R y se guarda su posición (η_R). Además se evalúa la señal $ECG(x)$ en este punto y el signo resultante se guarda en un registro. Posteriormente en el estado S3 se monitorea el punto η_{t1} , al detectarlo se activa un contador para comenzar la medición del ancho del complejo QRS. En el estado S4 se localiza η_{t2}

(Punto J) y se calcula el valor PRp. Finalmente, en el estado S5 se usan quince muestras de la señal $ECG(x)$ para determinar el signo del segmento ST y se guarda en un registro. Después de esto, los estados S6, S7 y S8 encuentran de manera similar los puntos η_T , η_{t1} y η_{t1} y el signo de la onda T. El bit de signo del ECG (η_T) detecta si existe una inversión en la onda T. Una vez que se obtiene el punto STp, la desviación del segmento ST se determina aplicando la ecuación 3 con los valores proporcionados por la RAM. El estado S9 establece la concordancia con otras curvas, comparando el bit de signo de cada curva con un multiplexor y una función XNOR. La máquina de estados vuelve al estado S1 iterando el proceso con el siguiente latido. De esta forma, las características del ECG del latido actual están listas para ser valoradas por la etapa de clasificación.

C. Clasificador (Etapa 3)

La etapa de clasificación se implementó mediante un sistema de lógica difusa digital. Para la descripción del sistema difuso se emplea el lenguaje VHDL y se sintetiza con celdas digitales estándar de la tecnología CMOS 180 nm. El sistema difuso consta de tres bloques funcionales principales:

1) *Bloque de fuzzificación*: La Fig. 6 muestra los bloques digitales necesarios para fuzzificar las características del ECG. Este proceso consiste en asociar grados de membresía a los valores de cada característica mediante memorias ROM. Se utilizan funciones de membresía trapezoidales. Cada memoria tiene un número diferente de posiciones de acuerdo con el rango de valores en cada característica. Como se puede apreciar, para la fuzzificación del ancho del complejo QRS se generan dos salidas y para el segmento ST se generan tres. Además, en el análisis difuso se incluye la inversión de la curva T y la concordancia entre las curvas.

2) *Matriz de relación-agregación*: Este bloque compara los valores de salida de fuzzificación, y toma el valor de grado mínimo de cada comparación para formar la matriz de relación, de acuerdo con la implicación de Mamdani. Este bloque solo usa un conjunto de multiplexores conectados a

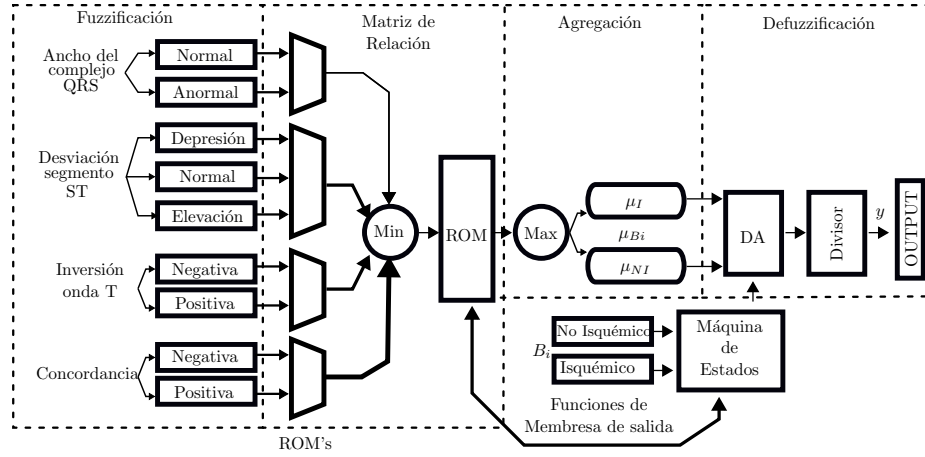


Fig. 6. Diagrama a bloques del clasificador implementado con lógica difusa digital.

las salidas de la ROM y un detector de valor mínimo. Una máquina de estados controla el orden de los valores correspondientes de cada función de membresía para ser comparados, de acuerdo con la lógica que establece en la Fig. 2 conformando la base de reglas difusas. Cada valor se guarda en una ROM. Posteriormente, la agregación ocurre cuando la máquina de estado selecciona y compara todos los elementos que apuntan a la misma salida. Luego, el valor máximo pasa a dos registros μ_I y μ_{NI} que representan la posibilidad de ser un latido isquémico y no isquémico respectivamente.

3) *Defuzzification*: Es un proceso que calcula el valor real y , a partir de los grados de activación de los conjuntos de salida. Este trabajo utiliza la ecuación centroide común:

$$y = \frac{\sum (\mu_{B_i} \cdot B_i)}{\sum \mu_{B_i}} \quad (4)$$

Donde μ_{B_i} es el resultado de la agregación, B_i es el resultado del grado de membresía correspondiente. Este bloque se divide en dos partes, la primera hace la multiplicación, la segunda divide y suma. Un esquema de aritmética distribuida (DA) realiza la multiplicación y la suma [23]. El bloque de división es con una multiplicación entre el dividendo y el inverso del divisor. Si la salida *OUTPUT* toma el valor 1, el latido es isquémico.

V. RESULTADOS Y DESEMPEÑO

1) *Simulación y síntesis del algoritmo*: Las tres etapas del algoritmo propuesto se describieron en VHDL y se simularon a nivel RTL con la base de datos Physionet. La prueba utiliza una población de latidos cardíacos de 100112. Donde 75581 componen el conjunto de latidos verdaderamente isquémicos, el conjunto no isquémico está formado por 16112 latidos cardíacos con desviación del segmento ST por causa de otros desordenes cardíacos, y 8482 son latidos normales para complementar la población total de latidos cardíacos. En cada grabación se consideraron las notas sobre el estado clínico del paciente. Las notas de las grabaciones de la base de datos que exhiben episodios isquémicos proporcionan el lapso de tiempo

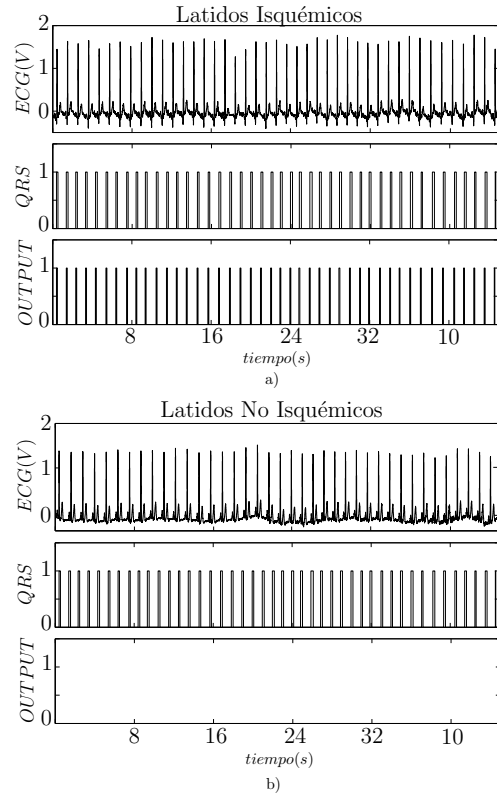


Fig. 7. Respuesta transitoria del algoritmo para una serie de latidos, a) Latidos realmente isquémicos b) Latidos no isquémicos con desviaciones en el segmento-ST.

de ocurrencia. La base de datos Long-Term ST Database de Physionet posee una frecuencia de muestreo de 250 Hz y 12 bit de resolución en un margen de señal de 1.8 V. De cada grabación del ECG se toman 10 minutos de latidos de un episodio isquémico. Esto es aproximadamente 600 latidos por cada evento. La Fig. 7 muestra la simulación de la respuesta transitoria del algoritmo propuesto con una serie de latidos isquémicos y la respuesta transitoria con una serie de latidos

Tabla III
COMPARISON OF PERFORMANCE FOR ISCHEMIA HEARTBEATS CLASSIFICATION

Referencia	Se %	Sp %	PPV %	Base de datos	Integración
[9]	94.4	93.4	86.9	European ST-T	NO
[10]	98.56	99.76	99.4	European ST-T	NO
[11]	98	98	–	90 patients	NO
[12]	81	88.1	86.3	Long-Term ST Database	NO
[13]	99	88.8	91.1	Long-Term ST Database	NO
[14]	88.7	86.8	87.4	Long-Term ST Database	NO
Este trabajo	98.7	97.23	96	Long-Term ST Database	Completamente



Fig. 8. Patrón geométrico (layout) del algoritmo propuesto.

no isquémicos. Observe la presencia de un pulso en la señal de “*OUTPUT*” cuando el latido es isquémico. Además, se muestra la detección del complejo QRS “*QRS*”, el ancho del puso corresponde al ancho del complejo QRS.

Este algoritmo se sintetizó con la herramienta de implementación física Encounter[®]. El algoritmo propuesto utiliza 1534 celdas digitales con una tecnología CMOS 180 nm. El reducido número de multiplicadores resalta la simplicidad del algoritmo propuesto. El circuito digital de resolución 12 bit usa un área de $490 \mu\text{m} \times 400 \mu\text{m}$ (Ver Fig. 8), que consume 1.086 mW.

2) *Resultados en Simulación:* El algoritmo propuesto fue puesto a prueba mediante simulación en dos experimentos, el primero considera latidos realmente isquémicos y latidos sanos, el segundo considera latidos no isquémicos y latidos normales. Además, los casos se simulan para dos escenarios, en el primero el algoritmo solo considera la desviación del segmento ST como indicativo de isquemia, es decir, no se incluye la clasificación por lógica difusa y en el segundo el algoritmo considera las 4 características y el sistema difuso. El rendimiento del algoritmo propuesto en la primera parte de la prueba, utiliza una población de latidos cardíacos de 75581, donde 39441 son latidos isquémicos y 36000 son latidos normales. La predicción positiva en ambos casos es cercana a 96%. Este resultado además de mostrar un alto rendimiento en la detección de desviaciones en el segmento ST, revela la eficiencia del algoritmo propuesto para detectar los puntos de interés en el ECG (η_{I1} , η_{I2} , η_R , η_{t1} , η_{t2} y η_T). Por otro lado, es relevante comentar que el valor predictivo negativo (*NPV*) es ligeramente menor durante la prueba de cuatro descriptores (94.5% en comparación con 96.4%) esto como resultado

del aumento en los falsos negativos en algunas grabaciones. La segunda parte de la prueba destaca significativamente la contribución del trabajo. La población de latidos consta de 12544 latidos anormales no isquémicos y 12000 latidos normales. La especificidad es la métrica que se utiliza debido a la ausencia de latidos isquémicos. En este caso, si el algoritmo de clasificación solo considera el segmento ST, la tasa de falsos positivos aumenta dramáticamente y en consecuencia la especificidad es muy baja (48.6%). Contrariamente, el algoritmo propuesto (considerando las cuatro características del ECG) muestra un valor de especificidad de 97.6%. La unión de los resultados de los dos experimentos da como resultado una sensibilidad de 98.6% y una especificidad de 97.23%. La tabla III muestra una comparación del rendimiento de otros trabajos y el trabajo propuesto (en los dos escenarios).

VI. CONCLUSIONES

En este trabajo se presenta un algoritmo de clasificación de latidos isquémicos y no isquémicos a nivel integrado que implementa técnicas de diagnóstico médico a través de un sistema de lógica difusa. El algoritmo exhibe un alto rendimiento con un valor de predictividad de 96%. Las pruebas a nivel simulación post-síntesis arrojan una sensibilidad del 98.7% y una especificidad del 97.23%. La síntesis digital de este algoritmo demanda una área activa de (490×400) micrómetros cuadrados con un consumo de energía de tan solo $13.15 \mu\text{W}$ a 1.8 V. Las características del algoritmo propuesto lo hacen factible para su fabricación física en un sistema integrado portable. La principal limitación para su aplicación en un sistema real portable radica en el desarrollo a nivel integrado del bloque de adquisición de datos y un ADC que garanticen lecturas ECG confiables. Sin embargo, este trabajo ya puede incorporarse en sistemas de monitoreo cardíaco ya existentes como un marcapasos con el fin de evaluar su rendimiento en tiempo real.

REFERENCES

- [1] J. Yeun-Ho, “Development of implantable medical devices: From an engineering perspective,” *Int Neurolog J*, vol. 17, no. 3, pp. 98–106, 2013. [Online]. Available: <http://www.einj.org/journal/view.php?number=131>
- [2] A. Kumar and J. Pillai, “Chapter 13 - implantable drug delivery systems: An overview,” in *Nanostructures for the Engineering of Cells, Tissues and Organs*, A. M. Grumezescu, Ed. William Andrew Publishing, 2018, pp. 473 – 511. [Online]. Available: <http://www.sciencedirect.com/science/article/pii/B9780128136652000132>
- [3] S. D. Girouard and Q. Zhu, “Implantable Device for Delivering Cardiac Drug Therapy,” Sep. 25 2006, wO2004043522A1. [Online]. Available: <https://patents.google.com/patent/WO2004043522A1/en>

- [4] R. F. Yi Zhang, "Ischemia detection using a heart sound sensor," Jul. 28 2009, uS8758260B2. [Online]. Available: <https://patents.google.com/patent/US8758260B2>
- [5] N. Holmstrom and M. Broome, "Ischemic region detection," Jul. 25 2006, uS20130190582. [Online]. Available: <https://patents.google.com/patent/US20130190582>
- [6] M. Raihan, P. K. Mandal, M. M. Islam, T. Hossain, P. Ghosh, S. A. Shaj, A. Anik, M. R. Chowdhury, S. Mondal, and A. More, "Risk prediction of ischemic heart disease using artificial neural network," in *2019 International Conference on Electrical, Computer and Communication Engineering (ECCE)*, Feb 2019, pp. 1–5.
- [7] M. Pirozzi, F. Pietroni, S. Casaccia, L. Scalise, and G. M. Revel, "Cardiac activity classification using an e-health app for a wearable device," in *2018 IEEE International Symposium on Medical Measurements and Applications (MeMeA)*, June 2018, pp. 1–6.
- [8] M. Salazar, J. Barochiner, W. Espeche, and I. Ennis, "Covid-19, hipertensión y enfermedad cardiovascular," *Hipertensión y Riesgo Vascular*, 06 2020.
- [9] H. Wang, W. Zhao, Y. Xu, J. Hu, C. Yan, D. Jia, and T. You, "ST segment change classification based on multiple feature extraction using ecg," in *2018 Computing in Cardiology Conference (CinC)*, vol. 45, Sep. 2018, pp. 1–4.
- [10] A. Bakhshipour, M. Pooyan, H. Mohammadnejad, and A. Fallahi, "Myocardial ischemia detection with ecg analysis, using wavelet transform and support vector machines," in *2010 17th Iranian Conference of Biomedical Engineering (ICBME)*, Nov 2010, pp. 1–4.
- [11] J. Fayn, "A classification tree approach for cardiac ischemia detection using spatiotemporal information from three standard ecg leads," *IEEE Transactions on Biomedical Engineering*, vol. 58, no. 1, pp. 95–102, Jan 2011.
- [12] M. W. Zimmerman, R. J. Povinelli, M. T. Johnson, and K. M. Ropella, "A reconstructed phase space approach for distinguishing ischemic from non-ischemic ST changes using Holter ECG data," in *Computers in Cardiology, 2003*, Sep. 2003, pp. 243–246.
- [13] P. Langley, E. J. Bowers, J. Wild, M. J. Drinnan, J. Allen, A. J. Sims, N. Brown, and A. Murray, "An algorithm to distinguish ischaemic and non-ischaemic ST changes in the Holter ECG," in *Computers in Cardiology, 2003*, Sep. 2003, pp. 239–242.
- [14] C. B. Vilakazi, L. Tarassenko, and G. D. Clifford, "Distinguishing between supply ischaemic and non-supply ischaemic ST events using a Relevance Vector Machine," in *2011 Computing in Cardiology*, Sep. 2011, pp. 633–636.
- [15] C. Papaloukas, D. I. Fotiadis, A. Likas, A. P. Liavas, and L. K. Michalis, "A robust knowledge-based technique for ischemia detection in noisy ecgs," in *KES'2000. Fourth International Conference on Knowledge-Based Intelligent Engineering Systems and Allied Technologies. Proceedings (Cat. No.00TH8516)*, vol. 2, Aug 2000, pp. 768–771 vol.2.
- [16] H. Tonekabanipour, A. Emam, M. Teshnelab, and M. A. Shoorhdeli, "Ischemia prediction via ecg using mlp and rbf predictors with anfs classifiers," in *2011 Seventh International Conference on Natural Computation*, vol. 2, July 2011, pp. 776–780.
- [17] G. B. Moody and F. Jager, "Distinguishing ischemic from non-ischemic ST changes: the Physionet/Computers in Cardiology Challenge 2003," in *Computers in Cardiology, 2003*, Sep. 2003, pp. 235–237.
- [18] Coppola G1 and Carità P and Corrado E and Borrelli A and Rotolo A and Guglielmo M and Nugara C and Ajello L and Santomauro M and Novo S, "ST segment elevations: always a marker of acute myocardial infarction?" *Indian heart journal*, vol. 65, no. 4, pp. 412–423, 2013.
- [19] R. Schmid, J. L. Isaksen, R. Leber, H. Schmid, G. Generali, and R. Abächerli, "A Correction Formula for the ST-Segment Measurements of AC-Coupled Electrocardiograms," *IEEE Transactions on Biomedical Engineering*, vol. 64, no. 8, pp. 1834–1840, Aug 2017.
- [20] E. B. Hanna and D. L. Glancy, "ST-segment depression and T-wave inversion: Classification, differential diagnosis, and caveats," *CLEVELAND CLINIC JOURNAL OF MEDICINE*, vol. 6, no. 78, p. 404–4014, 2011.
- [21] Y. Min, H. Kim, Y. Kang, G. Kim, J. Park, and S. Kim, "Design of Wavelet-Based ECG Detector for Implantable Cardiac Pacemakers," *IEEE Transactions on Biomedical Circuits and Systems*, vol. 7, no. 4, pp. 426–436, Aug 2013.
- [22] N. Milosavljevic and A. Petrovic, "ST Segment Change Detection by Means of Wavelets," in *2006 8th Seminar on Neural Network Applications in Electrical Engineering*, Sep. 2006, pp. 137–140.
- [23] M. S. Prakash and R. A. Shaik, "A distributed arithmetic based approach for the implementation of the sign-lms adaptive filter," in *2015 International Conference on Signal Processing and Communication Engineering Systems*, Jan 2015, pp. 326–330.



Gisela De La Fuente-Cortes was born in Mexico City in 1987. She received her B. Sc. degree in Electronic Engineering at the Autonomous University of Puebla, Mexico in 2012. Received the M. Sc. and Ph. D. at the National Institute for Astrophysics, Optics, and Electronics (INAOE) Puebla Mexico in 2014 and 2019 respectively. Currently she is collaborating as a postdoc fellow at the laboratory of circuits and systems design of Autonomous University of Puebla, Mexico 2019-2020. Her research interests include Analog and Mixed Integrated Circuit Design, Robust Design of Analog Integrated Circuits, and Medical applications.



J. Alejandro Diaz-Mendoza is a Full Researcher in the Electronics Department at INAOE. He received his BSc degree from Universidad Veracruzana, México; followed by M.Sc and Ph.D. degrees from Instituto Nacional de Astrofísica, Óptica y Electrónica (INAOE), México, in 1995 and 1999 respectively. In 1999 he was appointed as professor-Researcher at Instituto Politécnico Nacional, México. He has authored 30 Journal papers and around 80 conference papers. He has been a member of technical committees in national and international conferences. He is an IEEE Senior member and a member of national researcher's system of México.



Guillermo Espinosa was born in Mexico City, he obtained the M. Sc. degree from INAOE, Mexico, and the Ph. D. degree from Pavia University, Italy in 1983 and 1989. From 1980 to 1985 he worked in the Electronic Engineering Dept. at the Autonomous University of Puebla, Mexico. From 1990 to 1993 he worked in the Central Research and Development Dept. at SGS- THOMSON Microelectronics Corp., Italy, as head of the Analog Library Automation Group. In February 1993, he joined the Electronics Dept. at the National Institute of Astrophysics, Optics and Electronics (INAOE), Mexico as a Professor Researcher. He was with Freescale Semiconductor from 2005 to 2008 leading the Freescale Mexico Technology Center. Since 2008, he is, again, at INAOE Electronics Department as a Professor Researcher. His main research interests are in Analog and Mixed Integrated Circuit Design and CAD development for the automatic design, synthesis, analysis and layout of ICs, also he is interested in Robust Design of Analog Integrated Circuits, Medical applications, and Communications Systems.



Victor Rodolfo Gonzalez-Diaz was born in Puebla, Mexico. Received the M. Sc. and Ph. D. at the National Institute for Astrophysics, Optics and Electronics (INAOE) Puebla Mexico in 2005 and 2009 respectively. He collaborated as a postdoc fellow at the Microsystems Laboratory of University of Pavia, Italy from 2009-2010. Since 2011 he is full time professor at the Faculty of Electronics BUAP, Puebla. His main research interests are frequency synthesizers, data converters and Sigma-Delta modulation for analog and digital applications.