

Modelo secuencial de lógica difusa para la predicción de riesgo de muerte súbita cardíaca en niños con predisposición a SQTL

Oscar Vélez-Mora¹, Ulises Juárez-Martínez¹,
Alberto Alfonso Aguilar Lasserre¹, Ignacio López-Martínez,
Beatriz Alejandra Olivares Zepahua¹,
Norma Alicia Balderrábano-Saucedo²

¹ Tecnológico Nacional de México, Instituto Tecnológico de Orizaba,
División de Estudios de Posgrado e Investigación,
México

² Laboratorio de Investigación en Cardiopatías Congénitas y Arritmias,
Hospital Infantil de México Federico Gómez,
México

{M08011407, ulises.jm, alberto.al, ignacio.lm,
beatriz.oz}@orizaba.tecnm.mx, nbalderrabano@himfg.edu.mx

Resumen. La Muerte Súbita Cardíaca (MSC) se refiere a la interrupción brusca e inesperada de toda actividad cardíaca. En niños, dos grupos de enfermedades aumentan la probabilidad de MSC: las estructurales y las eléctricas, siendo el Síndrome de QT Largo (SQTL) recurrente en la población infantil mexicana. Este estudio busca diagnosticar el riesgo de MSC en niños mediante un modelo de lógica difusa secuencial. Se utilizan 4 variables en el primer modelo y 11 en el segundo, relacionadas con electrocardiogramas, síntomas e historial del paciente. Las salidas en el modelo ECG (electrocardiograma) son alto, medio y bajo riesgo; en el modelo clínico, son probable, poco probable y definitivo. Para la validación se utilizó una muestra de 69 pacientes del Hospital Infantil de México Federico Gómez, alcanzando una precisión del 97.7%.

Palabras clave: Lógica difusa, muerte súbita cardíaca, inteligencia artificial.

Sequential Fuzzy Logic Model for Predicting the Risk of Sudden Cardiac Death in Children Predisposed to LQTS

Abstract. The Sudden Cardiac Death (SCD) refers to the abrupt and unexpected cessation of all cardiac activity. In children, two groups of diseases increase the likelihood of SCD: structural and electrical, with Long QT Syndrome (LQTS) being recurrent in the Mexican pediatric population. This study aims to diagnose the risk of SCD in children using a sequential fuzzy logic model. Four variables

are used in the first model and eleven in the second, related to electrocardiograms, symptoms, and patient history. The outputs in the ECG (electrocardiogram) model are high, medium, and low risk; in the clinical model, they are probable, unlikely, and definitive. For validation, a sample of 69 patients from the Federico Gómez Children's Hospital in Mexico was used, achieving an accuracy of 97.7%.

Keywords: Fuzzy logic, sudden cardiac death, artificial intelligence.

1. Introducción

La Muerte Súbita Cardíaca (MSC) es un padecimiento que afecta a millones de personas en el mundo y se demostró que es la causa del 20% al 30% de las muertes de origen cardíaco en personas adultas [1]. Sin embargo, en México no se reporta un organismo encargado de llevar estadísticas precisas sobre este padecimiento y mucho menos en la población pediátrica. En muchas ocasiones, las muertes por este suceso se catalogan como “causas desconocidas”. En 2015, el INEGI [2] reportó 3,842 decesos por causas no definidas (R95-R99), de estos números 514 corresponden a MSC, lo cual genera una problemática en cuanto al registro y seguimiento del padecimiento. Diversos estudios demuestran que las muertes por este padecimiento en niños están asociadas a dos grupos de enfermedades, las cuales se clasifican como padecimientos estructurales y eléctricos [1], siendo la MCD (Miocardiopatía Dilatada) y SQT (Síndrome de QT Largo) las más frecuentes [1]. No obstante, la falta de conocimiento por parte de los médicos de primer contacto y las personas en general hace que estos padecimientos pasen desapercibidos y los niños no reciban un tratamiento adecuado. Por otro lado, las investigaciones demuestran que la predicción de la muerte súbita o la identificación de los padecimientos que predisponen a la misma es posible mediante técnicas de inteligencia artificial, siendo la lógica difusa [3] y el aprendizaje automático [4] aplicado a electrocardiogramas electrónicos dos de las más destacadas [5]. Por lo anteriormente mencionado, en este trabajo se propone crear un algoritmo basado en lógica difusa para la predicción de riesgo de muerte súbita cardíaca en la población infantil de México.

2. Trabajos relacionados

En [6] los autores presentaron un modelo de predicción de riesgo de arritmias cardíacas mediante una combinación de lógica difusa y redes neuronales. Las variables de entrada fueron colesterol, presión arterial, actividad física, tabaquismo, edad, índice de masa corporal y la diabetes. Alcanzando una precisión del 99,3 % en la detección de enfermedades coronarias superando a los clasificadores tradicionales KNN y SVM.

En [7] se propuso el desarrollo de un sistema experto aplicando lógica difusa para respaldar el diagnóstico de enfermedades coronarias en Nigeria, se emplearon 12 variables de entrada, como edad, presión arterial, glucosa, colesterol, ritmo cardíaco, entre otras, la variable resultante fue el diagnóstico de riesgo, categorizado como bajo, medio, moderado y severo alcanzando una precisión, sensibilidad y especificidad del 94,55%, 95,35% y 95,00% respectivamente.

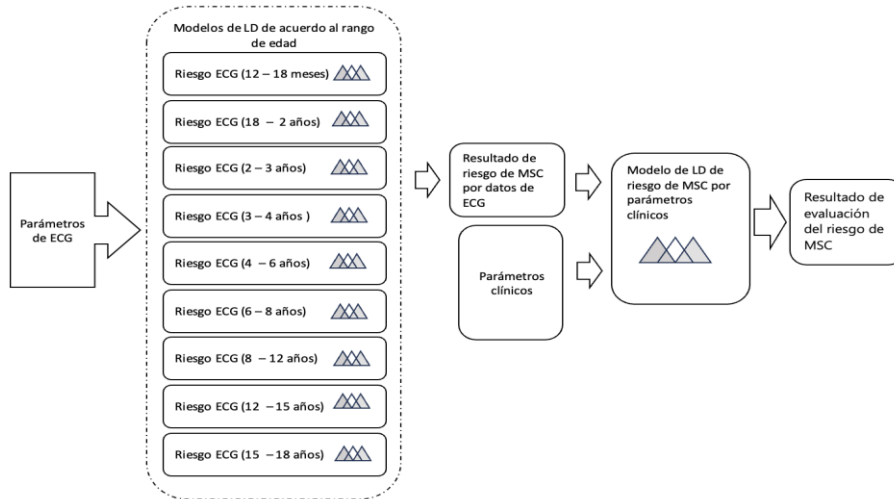


Fig. 1. Modelo secuencial de lógica difusa propuesto.

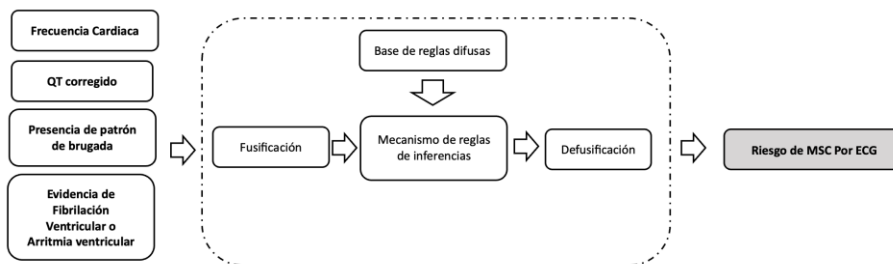


Fig. 2. Modelo secuencial de lógica difusa para predecir el riesgo de MSC por datos de ECG.

Por otro lado, Arslankaya et al. [8] diseñaron un modelo de lógica difusa que incorpora parámetros como la edad, género, niveles de colesterol, concentración de glucosa, presencia de angina inducida por el ejercicio, entre otros.

Se emplearon un total de 576 reglas de inferencia en la construcción del modelo. La efectividad del modelo se puso a prueba en un grupo de 10 pacientes y, mediante un análisis de regresión múltiple, se determinó que la relación entre las variables de entrada y salida.

En [9], los autores determinaron los factores relacionados con eventos de arritmias peligrosas en un estudio multicéntrico que involucró a un total de 13 instituciones. En este estudio se incluyeron a 72 pacientes con Tetralogía de Fallot (TOF) con taquicardia ventricular sostenida, una arritmia vinculada a la muerte súbita cardíaca. Los resultados finales utilizando Random Forest mostraron una sensibilidad del 54% (IC del 95%: del 44% al 63%) y una especificidad del 86% (IC del 95%: del 83% al 89 %).

Asimismo, Kasbe et al. [10] presentaron un modelo de diagnóstico para la predicción de enfermedades cardíacas utilizando Lógica Difusa. En este estudio, se utilizaron 13 parámetros de entrada, destacando la presión arterial, el colesterol, el nivel de azúcar

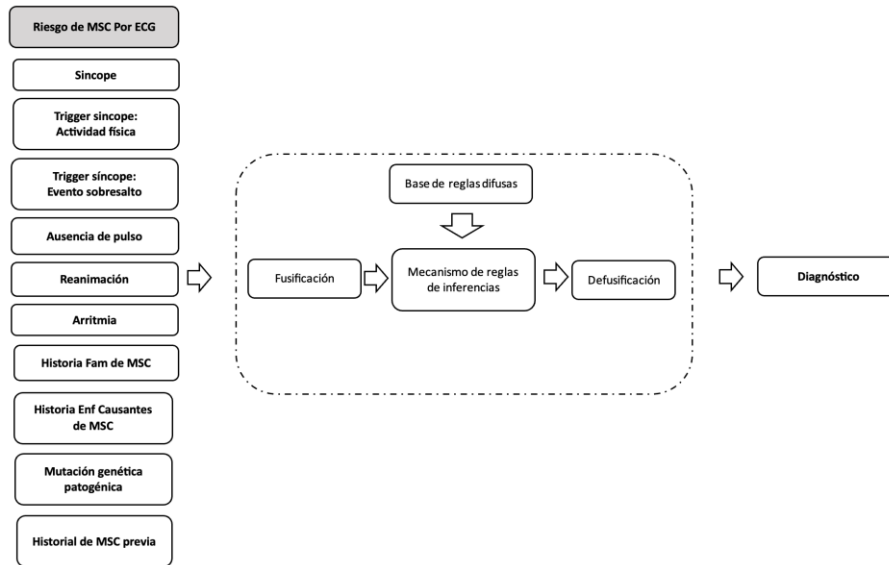


Fig. 3. Modelo secuencial de lógica difusa para predecir el riesgo de MSC por datos clínicos e historial del paciente.

Tabla 1. Relación de frecuencias cardiacas representado por rango de edades.

Edad	Frecuencia cardiaca
12 a 18 meses	88 - 156
18 a 24 meses	82 -149
2 – 3 años	76 - 142
3 – 4 años	70 - 136
4 – 6 años	65 - 131
6 – 8 años	59 - 123
8 – 12 años	52 - 115
12 – 15 años	47 - 108
15 – 18 años	43 - 104

en la sangre, el tipo de dolor torácico y la frecuencia cardíaca máxima, entre otros. Este modelo logró una precisión del 93.33%.

En [11] los autores propusieron un Sistema de Inferencia Neuro-difusa Adaptativa (ANFIS) para identificar seis afecciones cardíacas diferentes, que incluyen el bloqueo de rama derecha, contracción auricular prematura, contracción ventricular prematura, entre otras. Las variables de entrada utilizadas incluyeron la amplitud de la onda Q, el intervalo QRS, entre otras, logrando una especificidad media del 96.67%.

De igual forma Chugh et al. [12] presentaron un modelo de aprendizaje híbrido que combina algoritmos de aprendizaje automático como Random Forest, Gradient Boosting, eXtreme Gradient Boosting, entre otros, junto con un sistema experto difuso

Tabla 2. Variables de entrada del modelo de lógica difusa de datos de ECG (Modelo de niños de 12 meses).

Atributo (Factor de riesgo)	Conjuntos difusos	Valores
Frecuencia cardiaca (lpm)	Taquicardia	>140
	Normal	112 – 132
	Bradicardia	<103
QT corregido (ms)	Corto	<330
	Normal	370 – 470
	Largo	>480
Presencia de patrón de Brugada	Si	1
	No	0
FV o AV	Si	1
	No	0

Tabla 3. Variables de salida del modelo de lógica difusa por datos de ECG.

Nivel de riesgo por parámetros	Puntaje
Alto	>70
Medio	45 – 65
Bajo	<40

para la detección de enfermedades vasculares. Lograron una precisión del 91,2% en la UCI de Cleveland y del 91,7% en Framingham.

3. Software y herramientas utilizados

Para el diseño del modelo de lógica difusa se utilizó Python 3.11.0, JupyterLab 4.0.11, la biblioteca scikit-fuzzy 0.2, pandas 2.2.1, matplotlib y NumPy. Para el gráfico de superficie de respuesta, se empleó la biblioteca Plotly. Los requerimientos de hardware recomendados son: un procesador x86 con una velocidad de reloj de al menos 1.5 GHz y al menos dos núcleos físicos, junto con 4 GB de memoria RAM.

4. Modelo de lógica difusa propuesto

La lógica difusa (LD) permite la toma de decisiones basada en términos subjetivos expresados a través de variables lingüísticas [13]. Estas variables se valoran, modelan, fuzzifican, analizan mediante un mecanismo de inferencia y finalmente se defuzzifican. En el contexto de este estudio, se presenta un modelo secuencial de lógica difusa tipo Mamdani que recopila el conocimiento de diferentes expertos en muerte súbita cardiaca en edad pediátrica, a partir de dos modelos especializados en dos áreas de interés.

El primer modelo se enfoca en la recepción de variables relacionadas con electrocardiogramas, ya que diversos estudios [14,15] han demostrado que el ECG es una herramienta de gran utilidad en el diagnóstico de enfermedades asociadas a la MSC. Por otro lado, el segundo modelo utiliza el resultado del primer modelo sumado a una




Fig. 4. Variable de frecuencia cardiaca (niños de 18 meses).




Fig. 5. Variable QTc.




Fig. 6. Variable patrón de Brugada y evidencia de FV o AV.




Fig. 7. Variable de salida Riesgo por ECG.




Fig. 8. Variables por riesgo por ECG.



Fig. 9. Variables binarias.

serie de parámetros clínicos identificados por especialistas en el diagnóstico de niños con enfermedades que predisponen a la MSC, incluyendo el síncope [16], taquicardia, historia familiar de MSC, entre otros. Dado que el objetivo principal del primer modelo es predecir el riesgo de MSC en la población infantil, es necesario contar con los valores de frecuencia cardíaca asociados a la edad del niño, ya que la estructura anatómica del corazón varía de acuerdo a la edad [17].

Para abordar este problema, se propone replicar este modelo en rangos específicos (universos del discurso) que se detallan en la Tabla 1. Es por ello que para la predicción

de riesgo de MSC por medio de ECG se necesitan un total de 9 modelos. En la Figura 1 se muestra el proceso general del modelo secuencial de lógica difusa propuesto, en la figura 2 se presenta a detalle el modelo por parámetros de ECG y en la figura 3 el modelo de lógica difusa por parámetros clínicos.

4.1. Selección de variables de entrada y salida para el modelo de predicción por valores de ECG

Las variables asociadas al modelo de predicción mediante electrocardiogramas se presentan en la tabla 2, las cuales fueron seleccionadas y revisadas con el respaldo de un panel de expertos en enfermedades cardíacas pediátricas y muerte súbita cardíaca. Entre estas variables se destacan el QT corregido, el patrón de Brugada y la presencia de Fibrilación Ventricular o Arritmia Ventricular debido a su valor predictivo en otras investigaciones [18-20].

4.2. Variables de salida

En la tabla 3 se muestran las variables de salida asociadas al modelo de predicción por ECG el cual tiene un puntaje acorde al nivel de riesgo.

4.3. Selección de variables de entrada y salida por parámetros clínicos

Los parámetros clínicos utilizados en este modelo abarcan síntomas asociados a la MSC en niños. Estas variables fueron seleccionadas con base en la experiencia de un panel de expertos en enfermedades asociadas a la MSC y se presentan en la Tabla 4.

4.4. Variables de salida

En la Tabla 5 se muestran las variables de salida relacionadas con el modelo de predicción basado en parámetros clínicos, el cual asigna un puntaje correspondiente al nivel de riesgo.

4.5. Función de membresía de los datos de electrocardiograma

La función de membresía de cada variable se describió en detalle en la tabla 2.

1. Frecuencia cardíaca: Esta variable se representa con 3 valores lingüísticos que incluyen taquicardia, frecuencia normal y bradicardia. Estos conjuntos difusos se muestran en la figura 4.
2. QT corregido. Es una variable que presenta tres valores representados por términos lingüísticos: corto, normal y largo. Estos conjuntos difusos se visualizan en la figura 5.

Tabla 4. Variables de entrada del modelo de lógica difusa por parámetros clínicos.

Variable Lingüística	Conjuntos difusos	Valores
Riesgo de MSC por ECG	Bajo	< 40
	Medio	45 - 65
	Alto	>70
Síncope	Si	1
	No	0
Ausencia de pulso	Si	1
	No	0
Reanimación o desfibrilación	Si	1
	No	0
Taquicardia o Arritmia	Si	1
	No	0
Historia Familiar de MSC	Si	1
	No	0
Historia Familiar de enf. asociadas a MSC	Si	1
	No	0
Diagnóstico de enfermedad asociada a MSC	Si	1
	No	0
Mutación genética patogénica	Si	1
	No	0
Evento de MSC en el pasado	Si	1
	No	0

Tabla 5. Variables de salida del modelo de lógica difusa parámetros clínicos.

Nivel de riesgo por parámetros clínicos	Puntaje
Definitivo	>70
Probable	45 – 65
Poco probable	<40

3. Presencia de patrón de Brugada y Evidencia de FV o AV. Tienen 2 valores representados por un valor numérico 1 para sí y 0 para no. Los conjuntos mencionados se observan en la figura 6.
4. Variable de salida Riesgo de MSC por ECG consta de 3 conjuntos difusos alto, medio y bajo, representados en la figura 7.

4.6. Función de membresía de los datos clínicos

Variables de entrada del modelo de LD de datos clínicos.

1. Variable de entrada: riesgo por ECG, consta de 3 conjuntos difusos: alto, medio y bajo. Se describe a detalle en la tabla 4, y los conjuntos difusos se aprecian en la figura 8.

Tabla 6. Ejemplo de reglas de inferencia del modelo de lógica difusa por datos de ECG.

No de regla	AV o FV	Patrón de Brugada	QTc	FC	Riesgo ECG
R1	si	si	corto	bradicardia	alto
R2	si	si	corto	normal	alto
R3	si	si	corto	taquicardia	alto
R4	si	si	normal	bradicardia	alto
R28	no	no	normal	bradicardia	medio
R29	no	no	normal	normal	bajo

Tabla 7. Ejemplo de reglas de inferencia del modelo de lógica difusa por datos clínicos.

NR ^a	R ^b	S ^c	A ^d	R ^e	A ^f	H ^g	HE ^h	D ⁱ	TA ^j	T ^k	M ^l	MP ^m	D ⁿ
R1	alto	sí	sí	sí	sí	sí	sí	sí	sí	sí	si	sí	definitivo
R2	alto	sí	sí	sí	sí	sí	sí	sí	sí	sí	si	no	definitivo
R3	alto	sí	sí	sí	sí	sí	sí	sí	sí	sí	no	sí	definitivo
R4	alto	no	sí	sí	sí	sí	sí	sí	sí	no	no	sí	probable
R5	alto	sí	no	no	no	no	no	no	no	no	no	no	probable
R6	bajo	no	no	no	sí	no	no	no	no	no	no	no	poco probable
R7	bajo	no	no	no	no	no	no	no	no	no	no	no	poco probable

2. Variables binarias. La función de membresía de cada variable se describe en detalle en la tabla 4. Las variables de entrada son de tipo binario, correspondiendo a 1 para sí y 0 para no, y se representan en la figura 9.

Variable de salida del modelo de LD de datos clínicos.

El diagnóstico consta de 3 conjuntos difusos: poco probable, probable y definitivo, los cuales se muestran en la figura 10 y se describen a detalle en la tabla 5

4.7. Reglas de inferencia

La Tabla 6 presenta un ejemplo de las reglas de inferencia empleadas en el modelo de predicción basado en parámetros de electrocardiogramas. Este modelo cuenta con 32 reglas de inferencia. Por otro lado, el modelo complementario que utiliza parámetros clínicos consta de 3,581 reglas, cuyo extracto se muestra en la Tabla 7:

^aNúmero de regla; ^bRiesgo de ECG; ^cSíncope; ^dAusencia de pulso; ^eReanimación o desfibrilación; ^fArritmia Ventricular o Fibrilación Ventricular ^gHistoria Familiar de MSC; ^hHistoria de Enfermedades asociadas a MSC; ⁱDiagnóstico de Enfermedades Asociadas a MSC; ^jTrigger de Síncope: Actividad Física; ^kTrigger de Síncope: Sobresaldo o Estres; ^lMutación Genética Patogénica; ^mMuerte Súbita Previa; ⁿDiagnóstico.




Fig. 11. Gráfico de superficie de respuesta con bajo riesgo de MSC (27.77 %).




Fig. 12. Gráfico de superficie de alto riesgo de MSC (78.19 %).

4.8. Análisis de gráficos de superficie de respuesta

En este análisis, se evaluó el desempeño del sistema difuso Mamdani. En la Figura 11, se observa un bajo riesgo de Muerte Súbita Cardíaca (MSC) en niños de 12 a 18 meses. Los valores indicados corresponden a un paciente con frecuencia cardíaca y QTc dentro de los rangos normales para su edad. Por otro lado, en la Figura 12, se evidencia un alto riesgo de MSC asociado a valores muy elevados de QTc y frecuencia cardíaca.

5. Resultado y discusión

5.1. Evaluación del modelo de lógica difusa

Para la evaluación del modelo, se utilizó una base de datos de pacientes del Hospital Infantil de México Federico Gómez. En todos los casos evaluados, se obtuvo el consentimiento de los padres para fines de investigación. La edad de los pacientes osciló entre 1 y 18 años, con un total de 69 pacientes en la cohorte. De estos, 56 fueron diagnosticados con Síndrome de QT Largo y 13 fueron niños sanos. La distribución por edades de los niños se muestra en la tabla 8.

Dado el carácter particular del Síndrome de QT Largo (SQT) y la escasez de información en bases de datos públicas sobre casos de niños mexicanos, la base de datos presenta un sesgo significativo hacia un número desproporcionado de casos de

Tabla 8. Distribución de niños por rango de edad.

Rangos de edad	Niños con SQTL	Niños Sanos
12 a 18 meses	1	1
18 a 24 meses	0	0
2 – 3 años	1	0
3 – 4 años	3	3
4 – 6 años	4	2
6 – 8 años	8	5
8 – 12 años	20	2
12 – 15 años	15	0
15 – 18 años	4	0
Total	56	13

Tabla 9. Matriz de confusión.

Clase Real / Clase Predicha	Definitivo	Probable	Poco Probable	
Definitivo	9	0	0	9
Probable	0	56	0	56
Poco probable	0	4	9	13

Tabla 10. Resultado del modelo de predicción.

Precisión	Sensibilidad	Especificidad	Puntuación F1
97.7%	89.74%	89.74%	92.78%

pacientes sanos y con SQTL. Esto ha limitado el uso de técnicas de aprendizaje automático. Sin embargo, la lógica difusa ofrece la ventaja de generar sistemas basados en reglas sin depender tanto de la cantidad de datos disponibles.

La evaluación del modelo a través de la matriz de confusión, como se muestra en la tabla 9, revela una clasificación correcta de 9 casos como 'Definitivo', 56 casos como 'Probable' y 9 casos como 'Poco Probable'. No obstante, se cometieron errores al clasificar 4 casos como 'Probable', lo que resultó en una precisión del 97.7%, una sensibilidad del 89.74% y un F1-score del 92.78%, también presentados en la tabla 9. Aunque la especificidad promedio fue ligeramente inferior, sugiere posibles desafíos en la correcta clasificación de ciertas clases, especialmente en el caso de la clase 'Poco Probable'.

6. Conclusiones y trabajo a futuro

Con base en los resultados obtenidos, se concluye que el uso de la lógica difusa es una herramienta viable para apoyar la clasificación del nivel de riesgo de Muerte Súbita Cardíaca en niños, especialmente aquellos con predisposición a SQTL, logrando

resultados prometedores con una precisión del 97.7%. Se ha observado que la categoría 'poco probable' es la que presenta mayores dificultades en la clasificación correcta.

Para futuros trabajos, se plantea mejorar la capacidad del modelo de predicción presentado, incluyendo variables asociadas a datos bajo estrés, como los obtenidos durante una prueba de esfuerzo. Asimismo, se considera la implementación de otras variables de ECG como el complejo QRS, segmento ST e intervalo PR, ya que en este estudio se consideraron exclusivamente los valores asociados al corazón en reposo.

Referencias

1. Cano-Hernández, K.S., Nava-Townsend, S., Sánchez-Boiso, A., Sánchez-Urbina, R., Contreras-Ramos, A., Erdmenger-Orellana, J.R., Balderrábano-Saucedo, N.A.: Prevalencia y espectro de las enfermedades que predisponen a la muerte súbita cardiaca en niños mexicanos: Una muestra obtenida del Hospital Infantil de México Federico Gómez. *Archivos de cardiología de México*, vol. 88, no. 4, pp. 268 (2018). DOI: 10.1016/j.acmx.2017.08.003.
2. INEGI: Mexico - Estadísticas Vitales. Defunciones Generales y Fetales 2015. https://www.inegi.org.mx/rnm/index.php/catalog/231/related_materials?idPro= (2024)
3. Iancu, Ion.: Heart Disease Diagnosis based on Mediative Fuzzy Logic. *Artificial intelligence in Medicine*, vol. 89, pp. 1–60 (2018). DOI: 10.1016/j.artmed.2018.05.004.
4. Atallah, J., Corcia, M., Gonzalez, C., Walsh, E.P.: Ventricular Arrhythmia and Life-Threatening Events in Patients with Repaired Tetralogy of Fallot. *The American Journal of Cardiology*, Elsevier BV, vol. 132, pp. 126–132 (2020). DOI: 10.1016/j.amjcard.2020.07.012.
5. Aziz, S., Ahmed, S., Alouini, M.-S.: ECG-based Machine-Learning Algorithms for Heartbeat Classification. *Scientific Reports*, vol. 11, no. 1, pp. 18738 (2021). DOI: 10.1038/s41598-021-97118-5.
6. Kora, P., Meenakshi, K., Swaraja, K., Rajani, A., Islam, M.K.: Detection of Cardiac Arrhythmia using Fuzzy Logic. *Informatics in Medicine Unlocked*, Elsevier BV, vol. 17, pp. 100257 (2019). DOI: 10.1016/j.imu.2019.100257.
7. Muhammad, L.J., Algehyne, E.A.: Fuzzy based Expert System for Diagnosis of Coronary Artery disease in Nigeria. *Health and technology*, vol. 11, no. 2, pp. 319–329 (2021). DOI: 10.1007/s12553-021-00531-z.
8. Arslankaya, S., Çelik, T.M.: Prediction of Heart Attack using Fuzzy Logic Method and Determination of Factors Affecting Heart Attacks. *International Journal of Computational and Experimental Science and Engineering*, vol. 7, no. 1, pp. 1–8 (2021). DOI: 10.22399/ijcesen.837731.
9. Atallah, J., Corcia, M., Gonzalez, C., Walsh, E.P.: Ventricular Arrhythmia and Life-Threatening Events in Patients with Repaired Tetralogy of Fallot. *The American Journal of Cardiology*, vol. 132, pp. 126–132 (2020). DOI: 10.1016/j.amjcard.2020.07.012.
10. Kasbe, T., Pippal, R.S.: Design of Heart disease Diagnosis System using Fuzzy Logic. In *International Conference on Energy, Communication, Data Analytics and Soft Computing*, pp. 3183–3187 (2017). DOI: 10.1109/ICECDS.2017.8390044.
11. Rivera, J., Rodriguez, K., Yu, X.-H.: Cardiovascular Conditions Classification using Adaptive Neuro-Fuzzy Inference System. In *IEEE International Conference on Fuzzy Systems*, pp. 1–6 (2019). DOI: 10.1109/FUZZ-IEEE.2019.8858896.

12. Chugh, M., Anantavrasilp, I., Thiemjarus, S.: Hybrid Multi-Model Fuzzy Ensemble Approach for Cardiovascular diseases Detection. In IEEE World AI IoT Congress, pp. 0454–0459 (2023). DOI: 10.1109/AIIoT58121.2023.10174458.
13. Zadeh, L.A.: Fuzzy logic. *Computer*, vol. 21, no. 4, pp. 83–93 (1988)
14. Holkeri, A., Eranti, A., Haukilahti, M., Anette E., Kerola, T., Kenttä, T.V., Tikkanen, J., Aapo L.: Predicting Sudden Cardiac Death in a General Population Using an Electrocardiographic Risk Score. *Heart*, vol. 106, no. 6, pp. 427–433 (2020). DOI: 10.1136/heartjnl-2019-315437.
15. Granados-Ruiz, M.A., Mendoza-Soto, A.: Marcadores electrocardiográficos de riesgo de muerte súbita. *Anales de Pediatría Continuada*, vol. 11, no. 4, pp. 218–227 (2013). DOI: 10.1016/S1696-2818(13)70141-0.
16. Koene, R.J., Adkisson, W.O., Benditt, D.G.: Syncope and the Risk of Sudden Cardiac Death: Evaluation, Management, and Prevention. *Journal of Arrhythmia*, vol. 33, no. 6, pp. 533–544 (2017). DOI: 10.1016/j.joa.2017.07.005.
17. Fleming, S., Thompson, M., Stevens, R., Heneghan, C., Plüddemann, A., Maconochie, I., Mant, D.: Normal Ranges of Heart Rate and Respiratory Rate in Children from Birth to 18 Years of Age: A Systematic Review of Observational Studies. *The Lancet*, vol. 377, no. 9770, pp. 1011–1018 (2011). DOI: 10.1016/S0140-6736(10)62226-X.
18. Márquez, M.F.: El síndrome de QT largo: Una breve revisión del diagnóstico electrocardiográfico incluyendo la prueba de Viskin. *Archivos de Cardiología de México*, vol. 82, no. 3, pp. 243–247 (2012)
19. Retana-Puigmartí, M., de Frutos-Echaniz, E., Castro-Acuña-Baixauli, I., Val-Jimenez, A.: Diagnosticar un síndrome de Brugada: El papel de la atención primaria. *SEMERGEN - Medicina de Familia*, vol. 37, no. 10, pp. 569–572 (2011). DOI: 10.1016/j.semerg.2011.05.015.
20. Hornero, F., Almendral, J.: Arritmias ventriculares. Aspectos generales. *Cirugía Cardiovascular*, vol. 17, no. 3, pp. 219–229 (2010). DOI: 10.1016/S1134-0096(10)70096-6.