

Detección del riesgo de muerte súbita cardíaca en población pediátrica mediante algoritmos de aprendizaje automático

Jesús Ruiz-Sastre, Ulises Juárez-Martínez*, Alberto Alfonso Aguilar-Lasserre, Ignacio López-Martínez, Beatriz Alejandra Olivares-Zepahua, Norma Alicia Balderrábano-Saucedo

Resumen—La muerte súbita cardíaca (MSC) en población pediátrica representa un desafío clínico significativo debido a la diversidad de sus causas y la ausencia de herramientas predictivas especializadas. A diferencia de los adultos, donde la cardiopatía isquémica predomina, en niños la MSC se asocia principalmente con enfermedades arritmicas, anomalías coronarias congénitas y trastornos eléctricos cardíacos hereditarios. Este trabajo presenta el desarrollo y evaluación de un módulo de software para la predicción del riesgo de MSC en niños utilizando técnicas de aprendizaje automático. La metodología implementa un enfoque híbrido que combina modelos de lógica difusa especializados por grupos etarios con algoritmos de clasificación supervisada. Se utilizó un conjunto de datos sintético de 3,866 casos distribuidos en nueve grupos etarios (12 meses a 18 años), con variables electrocardiográficas y clínicas validadas por cardiólogos pediatras. De los siete algoritmos evaluados (Regresión Logística, Random Forest, Gradient Boosting, SVM, KNN, Naive Bayes y Árbol de Decisión), Naive Bayes y SVM obtuvieron el mejor desempeño promedio (96.81 % exactitud, 96.77 % F1-Score), alcanzando el grupo de 18-24 meses la mayor precisión individual (99.07 % con SVM). El sistema propuesto constituye una herramienta de apoyo a la decisión clínica que contribuye a la detección temprana del riesgo de MSC en población pediátrica.

Palabras clave—Muerte súbita cardíaca, aprendizaje automático, clasificación, lógica difusa, población pediátrica, electrocardiograma.

Detection of Sudden Cardiac Death Risk in Pediatric Population Using Machine Learning Algorithms

?abstractname? —Sudden cardiac death (SCD) in pediatric populations represents a significant clinical challenge due to the diversity of its causes and the absence of specialized predictive tools. Unlike adults, where ischemic heart disease predominates, SCD in children is primarily associated with arrhythmic diseases, congenital coronary anomalies, and inherited cardiac electrical

disorders. This work presents the development and evaluation of a software module for predicting SCD risk in children using machine learning techniques. The methodology implements a hybrid approach that combines fuzzy logic models specialized by age groups with supervised classification algorithms. A synthetic dataset of 3,866 cases distributed across nine age groups (12 months to 18 years) was used, with electrocardiographic and clinical variables validated by pediatric cardiologists. Of the seven algorithms evaluated (Logistic Regression, Random Forest, Gradient Boosting, SVM, KNN, Naive Bayes, and Decision Tree), Naive Bayes and SVM achieved the best average performance (96.81% accuracy, 96.77% F1-Score), with the 18–24 month age group reaching the highest individual precision (99.07% with SVM). The proposed system constitutes a clinical decision support tool that contributes to the early detection of SCD risk in pediatric populations.

Index Terms—Sudden cardiac death, machine learning, classification, fuzzy logic, pediatric population, electrocardiogram.

I. INTRODUCCIÓN

La muerte súbita cardíaca (MSC) representa un evento clínico devastador que ocurre de manera inesperada, generalmente dentro de la primera hora desde el inicio de los síntomas, causada principalmente por arritmias cardíacas graves [7]. En la población pediátrica, la MSC muestra características distintivas: mientras que en adultos la cardiopatía isquémica constituye la principal causa, en niños y adolescentes se asocia predominantemente con condiciones hereditarias, incluyendo enfermedades arritmicas, anomalías congénitas de las arterias coronarias y miocardiopatía hipertrófica [4], [5].

Las estadísticas globales evidencian la magnitud del problema. En 2008 se registraron aproximadamente 17.3 millones de muertes por enfermedades cardiovasculares, de las cuales 2.19 millones fueron súbitas. En Estados Unidos, la MSC representa entre el 7% y el 18% de los decesos totales [7]. En México, durante 2021 se registraron cerca de 220,000 muertes cardiovasculares, estimándose aproximadamente 17,873 por MSC [8]. La detección temprana constituye un desafío crítico, dado que aproximadamente el 90% de las muertes súbitas en niños tienen origen cardiovascular [11], aunque la mayoría de herramientas predictivas existentes se centran en población adulta.

El presente trabajo desarrolla y evalúa un módulo de software basado en aprendizaje automático para la predicción del riesgo de MSC en niños. La contribución principal radica en un enfoque híbrido que combina modelos de

Manuscript received on 16/02/2026, accepted for publication on 14/04/2026. Corresponding author is Ulises Juárez-Martínez.

Jesús Ruiz-Sastre, Ulises Juárez-Martínez, Alberto Alfonso Aguilar-Lasserre, Ignacio López-Martínez, Beatriz Alejandra Olivares-Zepahua are with Tecnológico Nacional de México/Instituto Tecnológico de Orizaba, División de Estudios de Posgrado e Investigación, Orizaba, México.

Norma Alicia Balderrábano-Saucedo is with Laboratorio de Investigación en Cardiopatías Congénitas y Arritmias, Hospital Infantil de México Federico Gómez, México.

Emails: d{M24010205, ulises.jm, alberto.al, ignacio.lm, beatriz.oz}@orizaba.tecnm.mx, nbalderrabano@himfg.edu.mx.

lógica difusa especializados por grupos etarios con algoritmos de clasificación supervisada, considerando las variaciones fisiológicas del desarrollo pediátrico. Se utilizan modelos de lógica difusa validados para la generación de casos sintéticos, se entrenan y evalúan múltiples algoritmos de clasificación, y se validan los resultados con especialistas en cardiología pediátrica.

El documento se estructura de la siguiente manera: la Sección 2 revisa los trabajos relacionados; la Sección 3 detalla la metodología y el sistema híbrido; la Sección 4 presenta los resultados por desempeño y edad; la Sección 5 discute los hallazgos y limitaciones; y la Sección 6 expone las conclusiones y líneas futuras.

II. TRABAJOS RELACIONADOS

La aplicación de inteligencia artificial para la predicción de eventos cardiovasculares ha crecido significativamente en la última década. En el contexto pediátrico, Miron et al. [4] y Norrish et al. [5] desarrollaron modelos predictivos de MSC para pacientes con miocardiopatía hipertrófica (MCH), con resultados viables aunque específicos a dicha condición. Vélez et al. [11] implementaron un sistema basado en lógica difusa para población pediátrica general con una precisión del 97.7%.

En el análisis electrocardiográfico, Chang et al. [1] y Siontis et al. [10] demostraron la eficacia de redes neuronales convolucionales (CNN) para detectar anomalías cardíacas. Kumari et al. [3] clasificaron arritmias con 95.92% de precisión usando SVM. En modelos predictivos cardiovasculares, Shi et al. [9] predijeron la MSC mediante variabilidad de frecuencia cardíaca y k-NN, Kumar et al. [2] destacaron la superioridad de CNN (98%) frente a redes neuronales tradicionales, y Peng et al. [6] emplearon XGBoost con alta efectividad.

Si bien estos trabajos representan avances significativos, persisten limitaciones: la mayoría se centra en población adulta o en subgrupos pediátricos específicos como MCH, pocos consideran variaciones fisiológicas por grupo etario, y existe escasa integración entre modelos de lógica difusa y aprendizaje automático para el contexto pediátrico. El presente trabajo aborda estas limitaciones mediante un enfoque híbrido que combina lógica difusa para modelar incertidumbre clínica con algoritmos de clasificación supervisada.

III. METODOLOGÍA

A. Arquitectura del sistema

El sistema desarrollado implementa una arquitectura híbrida en capas que integra modelos de lógica difusa con algoritmos de aprendizaje automático. La arquitectura se estructura en cuatro capas principales: (1) capa de presentación con interfaz web responsiva, (2) capa de aplicación con API REST desarrollada en Django, (3) capa de dominio que contiene el motor de predicción y validación médica, y (4) capa de datos con PostgreSQL como gestor de base de datos. La Figura 1 ilustra la organización de los componentes del sistema. El artículo se enfoca en la evaluación de los algoritmos de clasificación y

su capacidad predictiva por grupo etario. La arquitectura del sistema se describe para contextualizar la integración de los modelos pero la evaluación de rendimiento de la API REST no constituye el objetivo del presente estudio.

La implementación utilizó Python 3.x con Scikit-learn (v1.3) para los algoritmos de clasificación, Pandas y NumPy para la manipulación de datos, y Django REST Framework para la API. Se garantizó reproducibilidad mediante `random_state=42` en todos los componentes estocásticos.


B. Adquisición de datos

Debido a la naturaleza de la MSC en la población pediátrica y a lo inesperado de estos eventos, existen pocos casos documentados en el expediente clínico del Hospital Infantil de México Federico Gómez (HIMFG). A nivel nacional, las estadísticas indican que en 2021 se registraron cerca de 220,000 muertes por enfermedades cardiovasculares, estimándose que al menos 17,873 de estos fallecimientos correspondieron a MSC [8]. Ante la escasez y la sensibilidad en materia de privacidad de los datos clínicos pediátricos reales, se recurrió a la generación de un conjunto de datos sintéticos. Es importante mencionar que los datos sintéticos generados no fueron arbitrarios, sino que fueron rigurosamente validados por un médico especialista en cardiología pediátrica. Para este proceso, se extrajo una muestra de 350 casos utilizando la técnica de muestreo aleatorio simple, los cuales fueron revisados detalladamente por el experto. Esta validación clínica confirmó la plausibilidad fisiológica de los parámetros electrocardiográficos por edad, la coherencia clínica de los factores de riesgo combinados y la pertinencia del diagnóstico asignado, garantizando así la relevancia y seguridad del conjunto de datos utilizado.

C. Modelos de lógica difusa

Se utilizaron los modelos de lógica difusa de Vélez et al. [11], que implementan una arquitectura secuencial de dos etapas. La primera etapa procesa datos electrocardiográficos mediante nueve modelos especializados por grupo etario (12-18 meses, 18-24 meses, 2-3, 3-4, 4-6, 6-8, 8-12, 12-15 y 15-18 años), considerando las variaciones fisiológicas de la frecuencia cardíaca durante el desarrollo pediátrico. Las variables de entrada incluyen: frecuencia cardíaca (FC, con funciones de membresía trapezoidales adaptadas por grupo etario), intervalo QT corregido (QTc, clasificado en corto, normal y largo), patrón de Brugada y arritmia ventricular (ambas binarias).

La segunda etapa integra el resultado electrocardiográfico con once variables clínicas binarias: síncope, ausencia de pulso, reanimación cardíaca previa, arritmia documentada, historia familiar de MSC, historia de enfermedad asociada a MSC, diagnóstico de enfermedad causante de MSC, síncope durante actividad física, síncope por estrés, mutación genética patogénica e historia personal de MSC previa.



?figurename? 1. Arquitectura del sistema.

D. Generación del conjunto de datos sintético

El conjunto de datos se generó combinando los modelos de lógica difusa con distribuciones probabilísticas clínicamente validadas. El proceso comprende: selección de grupo etario con distribución uniforme, generación de variables electrocardiográficas mediante distribuciones trapezoidales (70% en rango plano, 30% en rampas), generación de variables clínicas binarias con distribución ponderada 70-30 reflejando prevalencia real, y evaluación mediante lógica difusa para obtener la clasificación diagnóstica. El conjunto resultante comprende 3,866 registros con 16 variables predictoras, distribuidos de manera estrictamente balanceada para prevenir sesgos de entrenamiento: 1,295 registros (33.5%) en la categoría “Definitivo”, 1,331 registros (34.4%) a “Probable” y 1,240 registros (32.1%) a “Poco Probable”. Asimismo, los datos mantienen una distribución equitativa entre los nueve grupos etarios y se dividen en una proporción 80-20 (3,089 para entrenamiento, 777 para prueba).

Es importante reconocer que la generación de datos sintéticos mediante modelos de lógica difusa introduce una dependencia estructural entre las etiquetas de clase y las variables predictoras. Dado que los algoritmos de aprendizaje automático aprenden a replicar la función de mapeo del sistema difuso, las métricas de exactitud reportadas reflejan la capacidad de aproximación funcional más que el descubrimiento de patrones clínicos independientes.

Los modelos de lógica difusa fueron desarrollados y validados previamente por Vélez et al. [11] en colaboración directa con cardiólogos pediatras del HIMFG, lo que garantiza que las reglas de inferencia codifican conocimiento médico experto. Así, el objetivo del componente de modelos de

aprendizaje automático no es descubrir patrones nuevos, sino proporcionar un modelo computacionalmente eficiente y generalizable que aproxime la función difusa con alta fidelidad, facilitando su integración en un sistema clínico en tiempo real.

E. Algoritmos de clasificación

Se implementaron siete algoritmos de aprendizaje supervisado, seleccionados por su complementariedad para la detección de patrones médicos complejos: Regresión Logística ($max_iter = 1000$), Random Forest ($n_estimators = 100$), Gradient Boosting ($n_estimators = 100$), Support Vector Machine (SVM) con kernel RBF ($probability = True$), K-Nearest Neighbors (KNN) ($n_neighbors = 5$), Naive Bayes Gaussiano y Árbol de Decisión.

Este conjunto balancea la interpretabilidad de los modelos base con la robustez de los métodos de ensamble y no paramétricos frente a interacciones no lineales.

F. Preprocesamiento y entrenamiento

El preprocesamiento incluyó: (1) codificación de variables categóricas mediante *LabelEncoder*, (2) normalización de variables numéricas con *StandardScaler* ajustado exclusivamente sobre los datos de entrenamiento para prevenir la fuga de información.

Los datos se dividieron 80-20 con muestreo estratificado para mantener la distribución de clases diagnósticas (definitivo, probable, poco probable). Se implementó validación cruzada estratificada de 5 pliegues sobre el conjunto de entrenamiento para obtener estimaciones robustas del rendimiento. El parámetro *random_state = 42* se especificó en todos

los algoritmos con componentes aleatorios para garantizar reproducibilidad.

Las métricas de evaluación incluyen exactitud, F1-Score ponderado, sensibilidad, media, desviación estándar de validación cruzada y el Área Bajo la Curva (AUC) derivada de las curvas de Característica Operativa del Receptor (ROC) multiclase.

Además de las métricas globales, se calcularon métricas clínicas específicas por clase: sensibilidad (*recall*) y especificidad para la categoría de riesgo “definitivo”, dado que la detección de pacientes de alto riesgo constituye el objetivo clínico primario. La sensibilidad para esta clase indica la proporción de pacientes verdaderamente en riesgo crítico que el modelo identifica correctamente, mientras que la especificidad mide la capacidad de descartar adecuadamente a pacientes sin riesgo elevado.

G. Validación clínica

Un especialista en cardiología pediátrica validó los datos y clasificaciones del modelo en una muestra aleatoria de 350 casos (distribuidos en nueve grupos etarios), evaluando cuatro criterios: la plausibilidad fisiológica de la frecuencia cardíaca y el QTc, la coherencia clínica entre factores de riesgo y hallazgos electrocardiográficos, la pertinencia diagnóstica del riesgo asignado y la relevancia de las variables predictivas.

El sistema alcanzó una concordancia adecuada con el criterio del médico experto. Asimismo, se comprobó que el modelo refleja fielmente condiciones patológicas relevantes, como bradicardia, taquicardia y alteraciones asociadas a los síndromes de QT.

IV. RESULTADOS

A. Desempeño general de algoritmos

La Tabla I presenta el desempeño promedio de los siete algoritmos evaluados a través de los nueve grupos etarios.

?TABLENAME? I

DESEMPEÑO PROMEDIO DE ALGORITMOS (TODOS LOS GRUPOS ETARIOS).

Modelo	Accuracy	F1-Score	CV Mean
Naive Bayes	0.9681	0.9677	0.9561
SVM	0.9681	0.9677	0.9561
Logistic Regression	0.9668	0.9663	0.9541
Random Forest	0.9649	0.9644	0.8394
Gradient Boosting	0.9615	0.9609	0.9501
Decision Tree	0.9225	0.9224	0.9165
KNN	0.8422	0.8419	0.8140

Los resultados evidencian una estratificación clara del rendimiento algorítmico. Naive Bayes y SVM comparten el liderazgo con exactitud de 96.81% y F1-Score de 96.77%, seguidos por Regresión Logística (96.68%) y Random Forest (96.49%). Gradient Boosting mantiene rendimiento superior al 96%, mientras que Árbol de Decisión (92.25%) y KNN (84.22%) presentan desempeño inferior.

B. Resultados por grupo etario

La Tabla II presenta el desempeño del mejor modelo para cada grupo etario. Se observa que la exactitud varía entre 92.59% (12-18 meses) y 99.07% (18-24 meses), con Naive Bayes y SVM alternando como mejores clasificadores según el grupo.

?TABLENAME? II

RESUMEN DEL MEJOR MODELO POR GRUPO ETARIO.

Grupo Etario	Mejor Modelo	Accuracy	F1-Score	CV Mean
12-18 meses	SVM	0.9259	0.9218	0.8177
18-24 meses	SVM	0.9907	0.9907	0.8135
2-3 años	Extra Trees	0.9808	0.9799	0.7765
3-4 años	Naive Bayes	0.9722	0.9699	0.9131
4-6 años	Naive Bayes	0.9592	0.9602	0.8238
6-8 años	Random Forest	0.9626	0.9627	0.9233
8-12 años	Extra Trees	0.9741	0.9737	0.8414
12-15 años	Random Forest	0.9619	0.9621	0.7548
15-18 años	Random Forest	0.9569	0.9587	0.8905

Consistentemente, KNN mostró un rendimiento deficiente (75-87%) y *scores* de generalización casi nulos, resultando inadecuado para estas características. En contraste, los modelos probabilísticos (Naive Bayes) dominaron en preescolares (3-6 años), mientras que los algoritmos de ensemble (Random Forest, Extra Trees) destacaron en grupos de mayor edad.

B1. Grupo 18-24 meses: Mejor desempeño.: Este grupo obtuvo el rendimiento máximo del estudio usando SVM con 99.07% de exactitud (Tabla III). La matriz de confusión mostró una clasificación casi perfecta en todas las categorías, con un único error (un caso “poco probable” clasificado como “probable”). Este alto desempeño se explica por la estabilización de los parámetros cardiovasculares durante esta transición, lo que acentúa las diferencias entre estados normales y patológicos.

?TABLENAME? III

DESEMPEÑO DE MODELOS PARA EL GRUPO 18-24 MESES.

Modelo	Accuracy	F1-Score	CV Mean
SVM	0.9907	0.9907	0.8135
Gradient Boosting	0.9884	0.9884	0.9474
Logistic Regression	0.9874	0.9874	0.9502
Random Forest	0.9854	0.9854	0.9500
Naive Bayes	0.9834	0.9834	0.9501
Decision Tree	0.9651	0.9651	0.9240
KNN	0.9186	0.9186	0.8188

B2. Grupo 15-18 años: Mayor desafío.: Este grupo registró el desempeño más bajo (Tabla IV), explicado por la variabilidad fisiológica del final de la pubertad y la proximidad de los parámetros cardiovasculares a valores adultos. Utilizando Random Forest, la clasificación fue perfecta para las categorías “definitivo” y “probable”, registrando únicamente cinco errores en los casos “poco probable”. Notablemente, el acierto total en los casos “definitivo” garantiza que ningún paciente de alto riesgo sea omitido.

C. Análisis de matrices de confusión

La Figura 2 presenta las matrices de confusión de los mejores modelos seleccionados para cada grupo etario, lo que permite

?TABLENAME? IV

DESEMPEÑO DE MODELOS PARA EL GRUPO 15-18 AÑOS.

Modelo	Accuracy	F1-Score	CV Mean
Random Forest	0.9569	0.9587	0.8905
Logistic Regression	0.9567	0.9583	0.8524
Naive Bayes	0.9547	0.9557	0.8870
Gradient Boosting	0.9459	0.9370	0.8640
SVM	0.9364	0.9384	0.8880
KNN	0.8670	0.8670	0.0210

visualizar el patrón de clasificación y los tipos de errores cometidos.

Las matrices de confusión revelan un patrón de clasificación altamente confiable entre los distintos grupos etarios, donde algoritmos como SVM y Random Forest identificaron correctamente los casos de alto riesgo sin generar falsos negativos críticos. Los modelos clasificaron adecuadamente a la gran mayoría de los pacientes en las categorías “definitivo” y “probable”, concentrándose las discrepancias casi exclusivamente en la clase “poco probable”, donde una mínima cantidad de casos fue sobrestimada hacia niveles de mayor riesgo. Desde una perspectiva clínica, esta direccionalidad de errores resulta favorable para un sistema preventivo, la alta precisión en casos definitivos minimiza el riesgo de omitir pacientes críticos, mientras que el ligero sesgo hacia la sobrestimación prioriza la seguridad, garantizando la derivación oportuna a evaluación médica especializada.

D. Análisis de curvas ROC

Para evaluar la capacidad de discriminación diagnóstica de los modelos frente a la variabilidad fisiológica, se analizaron las curvas ROC multiclase de dos grupos representativos: 6 a 8 años y 15 a 18 años.

En el grupo de 6 a 8 años, el algoritmo Random Forest demostró un rendimiento sobresaliente con un AUC promedio micro de 0.958. La categoría de riesgo “definitivo” alcanzó un AUC de 0.964, mientras que las clases “Probable” y “Poco probable” obtuvieron valores de 0.975 y 0.914, respectivamente.

El grupo de 15 a 18 años representa un desafío mayor debido a la proximidad de los parámetros cardiovasculares a valores adultos. No obstante, el modelo mantuvo alta precisión discriminativa con un AUC promedio micro de 0.964, destacando un incremento en la capacidad predictiva para casos “definitivo” con un AUC de 0.988. Las clases “Probable” y “Poco probable” registraron valores de 0.977 y 0.947, respectivamente. Estos resultados, ilustrados en la Figura 3, confirman que el sistema garantiza alta fiabilidad para no omitir pacientes en el espectro de mayor riesgo crítico.

E. Análisis de importancia de variables

Para garantizar la interpretabilidad clínica del sistema y comprender el mecanismo de decisión subyacente de los algoritmos, se realizó un análisis de importancia de variables extrayendo los pesos relativos de los modelos.

La Figura 4 ilustra la distribución del peso predictivo para las características clínicas y electrocardiográficas en dos grupos representativos (15 a 18 años y 6 a 8 años).

El análisis reveló un patrón de decisión algorítmica altamente congruente con la fisiopatología del riesgo cardiovascular severo. A través de los grupos etarios evaluados mediante algoritmos basados en árboles de decisión y SVM, las variables de historial clínico crítico (destacando el síncope, la ausencia de pulso y la reanimación previa) dominaron la función de decisión del modelo. Las variables electrocardiográficas, como la frecuencia cardíaca y el intervalo QTc, actuaron como factores de ajuste secundario que permitieron discriminar los límites entre los riesgos “Poco probable” y “Probable”. Este comportamiento confirma que el modelo no fundamenta sus predicciones en ruido estadístico, sino que pondera prioritariamente la gravedad del cuadro clínico histórico del paciente pediátrico.

F. Comparación con estado del arte

La Tabla V presenta una comparación del sistema propuesto con trabajos relacionados en la literatura.

Es importante destacar que las métricas reportadas no son directamente comparables entre estudios, dado que cada trabajo emplea conjuntos de datos distintos, poblaciones objetivo diferentes y esquemas de clasificación heterogéneos, por lo que esta tabla debe interpretarse como un marco de referencia contextual y no como una comparación cuantitativa directa.


La contribución principal del presente trabajo no se enfoca en superar numéricamente las métricas de estudios previos, sino en tres aspectos diferenciadores: la cobertura de población pediátrica general sin restricción a una cardiopatía específica, la segmentación por nueve grupos etarios que respeta las variaciones fisiológicas del desarrollo, y la evaluación sistemática de siete algoritmos que permite identificar el modelo óptimo según las características de cada grupo de edad. Estas aportaciones abordan una brecha identificada en la literatura, donde la mayoría de los modelos predictivos de MSC se centran en población adulta o en subgrupos pediátricos específicos.

V. DISCUSIÓN

A. Interpretación de resultados

Los resultados demuestran la viabilidad del aprendizaje automático para predecir riesgo de MSC en población pediátrica, con exactitud superior al 96% en los mejores modelos. Este alto rendimiento está ligado al impacto del balance artificial aplicado al conjunto de datos. Al garantizar una distribución equitativa de las clases durante el entrenamiento, se previno este sesgo metodológico, forzando a los modelos a caracterizar con la misma profundidad los patrones electrocardiográficos e históricos de las clases patológicas minoritarias. Como consecuencia directa de este balance, la alta correlación entre exactitud y F1-Score (diferencias <0.002) confirma un equilibrio adecuado entre precisión y sensibilidad, aspecto crítico en diagnóstico médico.

Matrices de Confusión - Mejores Modelos por Grupo de Edad



?figurename? 2. Matrices de confusión de los mejores modelos por grupo de edad.

A diferencia de los enfoques tradicionales centrados en adultos, la superioridad de Naive Bayes y SVM sobre los algoritmos de ensamble sugiere que la estructura de los datos pediátricos favorece a los modelos probabilísticos y basados en *kernels*. Estos algoritmos demuestran ser excepcionalmente robustos para ponderar interacciones complejas en las variables electrocardiográficas de entrada. La capacidad del sistema para interpretar anomalías eléctricas sutiles, como la presencia del patrón de Brugada o las alteraciones del intervalo QTc, resulta fundamental para identificar patologías arrítmicas subyacentes antes de que desencadenen un evento fatal.

Adicionalmente, el análisis de importancia de variables resolvió la necesidad de explicabilidad en el entorno médico. Al demostrar que el modelo asigna más del 80% de la carga predictiva a eventos como el síncope o la reanimación previa, se valida que el algoritmo replica el razonamiento clínico

de un cardiólogo pediatra, ya que prioriza inmediatamente el historial para clasificar el riesgo y utiliza las métricas del electrocardiograma para perfilar el riesgo en pacientes asintomáticos o con historiales menos concluyentes.

El desempeño diferenciado por grupo etario refleja fielmente las características fisiológicas del desarrollo pediátrico. El rendimiento óptimo observado en el grupo de 18-24 meses (99.07%) corresponde a una etapa de estabilización fisiológica donde las divergencias entre un estado cardiovascular normal y uno patológico son más distintivas. Por el contrario, la ligera disminución en el rendimiento en adolescentes mayores (95.69%) ilustra el desafío algorítmico que representa la variabilidad hemodinámica y hormonal propia del final de la pubertad. Asimismo, el bajo rendimiento de KNN (84.22%) indica que los algoritmos basados exclusivamente en distancias geométricas simples no son apropiados para




Figure 3. Curvas ROC multiclase evaluadas con el algoritmo Random Forest.




Figure 4. Importancia relativa de las variables predictoras extraída de los modelos para los grupos etarios de 15 a 18 años (izquierda) y de 6 a 8 años (derecha).

Table 5. COMPARACIÓN CONTEXTUAL CON TRABAJOS RELACIONADOS.

Estudio	Métrica Principal	Población	Tipo de Datos	Clases
Propuesto	Accuracy: 96.81 %	Pediátrica general	Sintéticos (validados)	3
Vélez et al. [11]	Precisión: 97.70 %	Pediátrica general	Sintéticos (lógica difusa)	3
Miron et al. [4]	Precisión: >70 %	Pediátrica (MCH)	Clínicos reales	2
Norrish et al. [5]	Estadístico C: 0.69	Pediátrica (MCH)	Clínicos reales	2
Shi et al. [9]	Accuracy: 96.10 %	Adultos	Clínicos reales	2
Kumari et al. [3]	Accuracy: 95.92 %	Adultos	Clínicos reales	Multiclase

modelar la complejidad geométrica de este espacio de características mixtas.

No obstante, esta aproximación funcional tiene un valor práctico significativo: permite desplegar modelos ligeros en entornos clínicos sin requerir la ejecución completa del motor de inferencia difusa. La validación preliminar con dos casos clínicos reales del HIMFG sugiere que la transferencia del conocimiento difuso al modelo de ML produce clasificaciones clínicamente coherentes.

En particular, un paciente con Taquicardia Ventricular Polimórfica Catecolaminérgica (TVPC) fue clasificado correctamente como riesgo “definitivo” con confianza del

74.3%, y un paciente sano en tamizaje familiar fue clasificado como “poco probable”.

B. Limitaciones del estudio

El presente trabajo presenta las siguientes limitaciones:

- Datos sintéticos:** Aunque el conjunto de datos fue generado mediante modelos de lógica difusa validados clínicamente, la validación definitiva del sistema requiere evaluación con datos clínicos reales de pacientes pediátricos.
- Generalización geográfica:** Los modelos de lógica difusa se desarrollaron con datos del Hospital Infantil

de México Federico Gómez, lo que podría limitar su generalización a otras poblaciones.

3. **Variables consideradas:** El conjunto de 16 variables predictoras, aunque clínicamente relevante, no incluye información de estudios complementarios como ecocardiogramas o estudios genéticos detallados.
4. **Seguimiento longitudinal:** El sistema proporciona evaluación puntual del riesgo sin considerar la evolución temporal del paciente.

C. Implicaciones clínicas

El sistema desarrollado presenta características que favorecen su aplicabilidad clínica:

- **Minimización de falsos negativos:** La alta sensibilidad demostrada para la categoría “definitivo” garantiza que la probabilidad de no detectar pacientes en riesgo crítico se mantenga por debajo del 3% en todos los grupos etarios.
- **Sesgo hacia la sobrestimación:** Los errores observados tienden hacia la clasificación en categorías de mayor riesgo, lo cual es clínicamente preferible al favorecer evaluación adicional.
- **Adaptación al desarrollo pediátrico:** La disponibilidad de modelos específicos por grupo etario permite ajustar las predicciones a las características fisiológicas de cada paciente.

Es fundamental enfatizar que el sistema propuesto constituye una herramienta de apoyo a la decisión clínica que complementa, pero no reemplaza, el juicio médico especializado. Las predicciones deben interpretarse en el contexto clínico completo del paciente.

VI. CONCLUSIONES Y TRABAJO FUTURO

A. Conclusiones

El presente trabajo demuestra la viabilidad de desarrollar un módulo de *software* basado en aprendizaje automático para la predicción del riesgo de muerte súbita cardíaca en población pediátrica. Las principales conclusiones son:

1. El enfoque híbrido que combina lógica difusa con algoritmos de clasificación supervisada permite generar predicciones clínicamente relevantes, alcanzando exactitud promedio del 96.81% con Naive Bayes y SVM.
2. La especialización por grupo etario es fundamental para capturar las variaciones fisiológicas del desarrollo pediátrico, evidenciada por las diferencias de rendimiento entre grupos (desde 95.69% hasta 99.07%).
3. Los algoritmos probabilísticos (Naive Bayes) y basados en kernels (SVM) superan consistentemente a algoritmos de *ensemble* y basados en distancias para este problema específico.
4. El sistema demuestra un sesgo clínicamente favorable hacia la sobrestimación del riesgo, minimizando la probabilidad de falsos negativos en casos de alto riesgo.
5. La validación clínica con especialistas en cardiología pediátrica confirma la plausibilidad médica de las clasificaciones generadas.

B. Trabajo futuro

Las direcciones de investigación futura incluyen:

- **Validación prospectiva:** Evaluación del sistema con datos clínicos reales en entornos hospitalarios controlados.
- **Integración de variables adicionales:** Incorporación de datos ecocardiográficos, estudios genéticos moleculares y biomarcadores séricos.
- **Modelos de seguimiento longitudinal:** Desarrollo de algoritmos que consideren la evolución temporal del riesgo.
- **Técnicas de aprendizaje profundo:** Exploración de redes neuronales convolucionales para análisis directo de señales electrocardiográficas.
- **Validación multicéntrica:** Evaluación del sistema en múltiples instituciones para verificar generalización.

REFERENCIAS

- [1] S.-N. Chang *et al.*, “An artificial intelligence-enabled ECG algorithm for identifying ventricular premature contraction during sinus rhythm,” *Eur. J. Med. Res.*, vol. 27, no. 1, p. 289, 2022. 10.1186/s40001-022-00929-z
- [2] A. Kumar, K. Rathor, S. Vaddi, D. Patel, P. Vanjarapu, and M. Maddi, “ECG Based Early Heart Attack Prediction Using Neural Networks,” in *2022 3rd International Conference on Electronics and Sustainable Communication Systems (ICESC)*, 2022, pp. 1080–1083. 10.1109/ICESC54411.2022.9885448
- [3] Ch. Usha Kumari, A. Sampath Dakshina Murthy, B. Lakshmi Prasanna, M. Pala Prasad Reddy, and A. Kumar Panigrahy, “An automated detection of heart arrhythmias using machine learning technique: SVM,” *Mater. Today Proc.*, vol. 45, pp. 1393–1398, 2021. 10.1016/j.matpr.2020.07.088
- [4] A. Miron *et al.*, “A Validated Model for Sudden Cardiac Death Risk Prediction in Pediatric Hypertrophic Cardiomyopathy,” *Circulation*, vol. 142, no. 3, pp. 217–229, 2020. 10.1161/CIRCULATIONAHA.120.047235
- [5] G. Norrish *et al.*, “Development of a Novel Risk Prediction Model for Sudden Cardiac Death in Childhood Hypertrophic Cardiomyopathy (HCM Risk-Kids),” *JAMA Cardiol.*, vol. 4, no. 9, pp. 918–927, 2019. 10.1001/jamacardio.2019.2861
- [6] M. Peng *et al.*, “Prediction of cardiovascular disease risk based on major contributing features,” *Sci. Rep.*, vol. 13, no. 1, p. 4778, 2023. 10.1038/s41598-023-31870-8
- [7] H. Rodríguez-Reyes *et al.*, “Muerte súbita cardíaca. Estratificación de riesgo, prevención y tratamiento,” *Arch. Cardiol. Méx.*, vol. 85, no. 4, pp. 329–336, 2015. 10.1016/j.acmx.2015.06.002
- [8] Secretaría de Salud, “490. Cada año 220 mil personas fallecen debido a enfermedades del corazón,” *Gobierno de México*, s. f. [En línea]. <https://www.gob.mx/salud/prensa/490-cada-ano-220-mil-personas-fallecen-debido-a-enfermedades-del-corazon>
- [9] M. Shi *et al.*, “Early Detection of Sudden Cardiac Death by Using Ensemble Empirical Mode Decomposition-Based Entropy and Classical Linear Features From Heart Rate Variability Signals,” *Front. Physiol.*, vol. 11, p. 118, 2020. 10.3389/fphys.2020.00118
- [10] K. C. Siontis, P. A. Noseworthy, Z. I. Attia, and P. A. Friedman, “Artificial intelligence-enhanced electrocardiography in cardiovascular disease management,” *Nat. Rev. Cardiol.*, vol. 18, no. 7, pp. 465–478, 2021. 10.1038/s41569-020-00503-2
- [11] O. Vélez Mora y U. Juárez Martínez, “Desarrollo de un módulo de software para la predicción de riesgo de muerte súbita cardíaca en niños mediante técnicas de inteligencia artificial,” Tesis de Maestría, Instituto Tecnológico de Orizaba, México, 2024. Accedido: 3 de marzo de 2026. [En línea]. Disponible en: <http://repositorios.orizaba.tecnm.mx:8080/xmlui/handle/123456789/864>