



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación
Maestría en Sistemas Computacionales

OPCIÓN I.- TESIS:
TRABAJO PROFESIONAL

“Desarrollo de un módulo de software para la predicción de riesgo de muerte súbita
cardíaca en niños mediante técnicas de inteligencia artificial”

Presentado por:

I.S.C Oscar Vélez Mora

Para obtener el grado de:

Maestro en Sistemas Computacionales

Director de tesis:

Dr. Ulises Juárez Martínez

Codirector de tesis:

Dr. Alberto Alfonso Aguilar Lasserre



Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Orizaba, Veracruz, 18/octubre/2024
Dependencia: División de Estudios de
Posgrado e Investigación
Asunto: Autorización de Impresión
OPCION: I

C. OSCAR VÉLEZ MORA
CANDIDATO A GRADO DE MAESTRO EN:
SISTEMAS COMPUTACIONALES
P R E S E N T E.-

De acuerdo con el Reglamento de Titulación vigente de los Centros de Enseñanza Técnica Superior, dependiente de la Dirección General de Institutos Tecnológicos de la Secretaría de Educación Pública y habiendo cumplido con todas las indicaciones que la Comisión Revisora le hizo respecto a su Trabajo Profesional titulado:

" Desarrollo de un módulo de software para la predicción de muerte súbita cardiaca en niños mediante técnicas de inteligencia artificial "

comunico a Usted que este Departamento concede su autorización para que proceda a la impresión del mismo.

ATENTAMENTE
Excelencia en Educación Tecnológica®
CIENCIA – TÉCNICA - CULTURA®


DRA. OFELIA LANDETA ESCAMILLA
JEFA DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN



OG-13-F06





EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO

Instituto Tecnológico de Orizaba
División de Estudios de Posgrado e Investigación

Orizaba, Veracruz, 11/septiembre/2024
Asunto: Revisión de trabajo escrito

C. OFELIA LANDETA ESCAMILLA
JEFA DE LA DIVISIÓN DE ESTUDIOS
DE POSGRADO E INVESTIGACIÓN
P R E S E N T E.-

Los que suscriben, miembros del jurado, han realizado la revisión de la Tesis del (la) C.

OSCAR VÉLEZ MORA

La cual lleva el título de:

**Desarrollo de un módulo de software para la predicción de riesgo de muerte súbita cardíaca
en niños mediante técnicas de inteligencia artificial**

Y concluyen que se acepta.

ATENTAMENTE

Excelencia en Educación Tecnológica®
CIENCIA – TÉCNICA – CULTURA®

PRESIDENTE: DR. ULISES JUÁREZ MARTÍNEZ

**SECRETARIO: DR. ALBERTO ALFONSO AGUILAR
LASSERRE**

VOCAL: M.R.T. IGNACIO LÓPEZ MARTÍNEZ

**VOCAL SUP.: M.C.E. BEATRIZ ALEJANDRA
OLIVARES ZEPAHUA**

FIRMA

FIRMA

FIRMA

FIRMA

TA-09-18



Av. Oriente 9 Núm.852, Colonia Emiliano Zapata. C.P. 94320 Orizaba, Veracruz.
Tel. 01 (272)1105360 e-mail: dir_orizaba@tecnm.mx tecnm.mx | orizaba.tecnm.mx



2024
Felipe Carrillo
PUERTO
GOBIERNO DEL ESTADO DE VERACRUZ
GOBIERNO DEL INSTITUTO TECNOLÓGICO NACIONAL DE MÉXICO

CARTA DE ORIGINALIDAD

En la ciudad de Orizaba, Veracruz, el día 04 del mes de noviembre de 2024, el (la) que suscribe Oscar Vélez Mora, alumno (a) del programa de Maestría en Sistemas Computacionales con numero de control M08011407, manifiesta que es autor (a) del trabajo de tesis titulado "Desarrollo de un módulo de software para la predicción de riesgo de muerte súbita cardiaca en niños mediante técnicas de inteligencia artificial" y declara que el trabajo es original, ya que su contenido es producto de su directa contribución intelectual. Todos los datos y las referencias a materiales ya publicados están debidamente identificados con su respectivo crédito e incluidos en las notas bibliográficas y en las citas que se destacan como tal y, en los casos que así lo requieran, se tienen las debidas autorizaciones de quienes poseen los derechos patrimoniales. Por lo tanto, se hace responsable de cualquier litigio o reclamación relacionada con derechos de propiedad intelectual, exonerando de toda responsabilidad al Tecnológico Nacional de México/ Instituto Tecnológico de Orizaba.



Oscar Vélez Mora

Nombre y firma

CARTA DE CESION DE DERECHOS

En la ciudad de Orizaba el día 04 del mes de noviembre del año 2024, el (la) que suscribe Oscar Vélez Mora alumno (a) del programa de Maestría en Sistemas Computacionales con numero de control M08011407, manifiesta que es autor (a) intelectual de! trabajo de tesis bajo la dirección del Dr. Ulises Juárez Martínez y ceden los derechos del trabajo intitulado "Desarrollo de un módulo de software para la predicción de riesgo de muerte súbita cardiaca en niños mediante técnicas de inteligencia artificial" al TecNM/Instituto Tecnológico de Orizaba para su difusión, con fines académicos y de investigación.

Los usuarios de la información no deben reproducir el contenido textual, graficas o datos del trabajo sin el permiso expreso del autor y del director del trabajo. Este puede ser obtenido escribiendo a la siguiente dirección: msc@orizaba.tecnm.mx . Si el permiso se otorga, el usuario deberá dar el agradecimiento correspondiente y citar la fuente del mismo.



Oscar Vélez Mora

Nombre y firma

Agradecimientos

A mi madre, cuyo apoyo incondicional ha sido el pilar más fuerte durante todo este camino. Su aliento no comenzó en el posgrado, sino que ha estado presente en cada etapa de mi vida, impulsándome siempre a ser una persona íntegra y dedicada, tanto en lo académico como en lo profesional.

En memoria de mi tío, Víctor Mora Fuentes, quien desde mi infancia me inculcó el valor de la educación, la preparación académica y la importancia de trabajar con profesionalismo y honestidad. Su ejemplo ha sido una guía constante en mi vida.

Al Dr. Ulises Juárez Martínez, por su valioso apoyo y orientación académica durante el desarrollo de esta tesis, brindándome siempre sus conocimientos y su tiempo.

Al Dr. Alberto Alfonso Aguilar Lasserre, por su respaldo y su guía en el área de técnicas de inteligencia artificial, fundamentales para el avance de esta investigación. Sus aportaciones fueron invaluable para el desarrollo de este trabajo.

A la Dra. Norma Alicia Balderrábano Saucedo, cuya orientación constante y valiosas contribuciones resultaron cruciales en cada fase de esta investigación. Su dedicación y compromiso marcaron una gran diferencia en el resultado final.

Al Consejo Nacional de Humanidades, Ciencias y Tecnologías (CONAHCyT), por el apoyo invaluable que me ha brindado a lo largo de este proyecto. No solo agradezco profundamente el respaldo económico, que fue fundamental para poder llevar a cabo mis estudios y enfocarme en el desarrollo de esta investigación, sino también el acompañamiento institucional que me ofrecieron en todo momento.

Índice general

Resumen	XII
Abstract	XIII
Introducción	XIV
1. Antecedentes	1
1.1. Marco teórico	1
1.1.1. Inteligencia artificial	1
1.1.2. Lógica difusa	2
1.1.3. Muerte súbita cardíaca	3
1.1.4. Electrocardiograma	4
1.1.5. Arritmia cardíaca	5
1.1.6. Miocardiopatía hipertrófica	6
1.1.7. Fibrilación ventricular	6
1.1.8. Metodología UWE	7
1.2. Situación tecnológica, económica y operativa de la empresa	7
1.3. Planteamiento del problema	8
1.4. Objetivo general y objetivos específicos	9
1.4.1. Objetivo general	9
1.4.2. Objetivos específicos	9
1.5. Justificación	10
2. Estado de la práctica	11
2.1. Trabajos relacionados	11
2.2. Análisis comparativo	23
2.3. Propuesta de solución	30
3. Aplicación de la metodología	31
3.1. Arquitectura de la aplicación	32
3.1.1. Modelo de casos de uso UWE	34
3.1.2. Diagrama de clases	35
3.1.3. Modelo de proceso UWE	38
3.1.4. Modelo de navegación UWE	41
3.1.5. Modelo de presentación UWE	44
3.2. Descripción general del modelo de lógica difusa	47
3.2.1. Entorno de trabajo	49
3.2.2. Jupiter Notebooks	49
3.2.3. Configuración	49

3.2.4. Definición de variables lingüísticas	50
3.2.5. Análisis de inferencia	64
3.2.6. Análisis de superficie de respuesta	68
3.2.7. Configuración de los modelos de predicción de lógica difusa en Python	71
4. Resultados	75
4.1. Planteamiento del Caso de Estudio	75
4.2. Requerimientos del Negocio	75
4.3. Obtención de datos	76
4.4. Determinación de datos necesarios	76
4.5. Obtención de la base de datos	76
4.6. Matriz de confusión	80
4.7. Diseño de servicio REST en <i>Django</i> Rest Framework	80
4.7.1. Modelo de predicción de lógica difusa por parámetros clínicos	80
4.7.2. Angular Cli	86
4.8. Uso de la aplicación	88
4.8.1. Caso de estudio: Predicción de riesgo de muerte súbita cardíaca en un paciente pediátrico con SCTL	89
4.8.2. Caso de estudio: Predicción de riesgo de muerte súbita cardíaca en un paciente sano	92
4.8.3. Aportación al Estado de la Práctica	94
5. Conclusiones	95
5.0.1. Recomendaciones	96
A. Glosario de Términos Médicos	98
A.1. Introducción	98
A.2. Términos Médicos	98
A.2.1. Muerte Súbita Cardíaca (MSC)	98
A.2.2. Intervalo QTc	98
A.2.3. Frecuencia Cardíaca	98
A.2.4. Arritmia	99
A.2.5. Cardiomiopatía	99
A.2.6. Electrocardiograma (ECG)	99
A.2.7. Bradiarritmia	99
A.2.8. Taquiarritmia	99
A.2.9. Hipertrofia Ventricular	99
A.2.10. Fibrilación ventricular	99
Referencias	104

Índice de figuras

1.1. Lógica Booleana: El agua es clasificada como “fría” o “caliente” sin transi- ciones graduales.	3
1.2. Lógica Difusa: El agua puede ser “parcialmente fría” y “parcialmente calien- te” con transiciones graduales.	3
1.3. Enfermedades que predisponen la MSC en niños	4
3.1. Metodología del modelo de predicción de MSC en niños.	32
3.2. Arquitectura de la aplicación.	33
3.3. Diagrama de casos de uso	35
3.4. Diagrama de clases	37
3.5. Modelo de proceso	40
3.6. Modelo de navegación	43
3.7. Modelo de presentación de inicio de sesión	44
3.8. Modelo de presentación de sección principal	45
3.9. Modelo de presentación de sección pacientes	46
3.10. Modelo de presentación de la sección expediente	47
3.11. Modelo en cascada de lógica difusa para el riesgo de MSC	48
3.12. Relación de frecuencias cardíacas medidas en percentiles representado por rango de edades	48
3.13. Jupyter Notebook	49
3.14. Anaconda Navigator	50
3.15. Conjuntos difusos para frecuencia cardíaca	54
3.16. Conjuntos Difusos para QTc	56
3.17. Variable Binaria: Presencia de Patrón de Brugada	57
3.18. Variable Binaria: Presencia de Fibrilación Ventricular o Arritmia Ventricular	58
3.19. Conjuntos Difusos para Riesgo de MSC	59
3.20. Funciones de membresía para la variable con valores 1 y 0	63
3.21. Conjuntos Difusos para Diagnóstico	63
3.22. Relación del riesgo de MSC en función del QTc y la fc en niños de 12 a 18 meses.	70
3.23. Relación del riesgo de MSC en función del QTc y la fc en niños de 18 meses a 2 años	70
3.24. Relación del riesgo de MSC en función del QTc y la fc en niños de 2 a 3 años	70
3.25. Relación del riesgo de MSC en función del QTc y la fc en niños de 3 a 4 años	70
3.26. Relación del riesgo de MSC en función del QTc y la fc en niños de 4 a 6 años	70
3.27. Relación del riesgo de MSC en función del QTc y la fc en niños de 6 a 8 años	70
3.28. Relación del riesgo de MSC en función del QTc y la fc en niños de 8 a 12 años	71

3.29. Relación del riesgo de MSC en función del QTc y la fc en niños de 12 a 15 años	71
3.30. Relación del riesgo de MSC en función del QTc y la fc en niños de 15 a 18 años	71
3.31. Modelos de lógica difusa de acuerdo a la edad	74
4.1. Diagnóstico de los niños	77
4.2. Distribución de niños con SQTL y niños sanos por rangos de edad	78
4.3. Inicio de sesión	89
4.4. Dashboard	89
4.5. Expediente	90
4.6. Formulario de predicción de riesgo	91
4.7. Resultado de predicción parte 1	91
4.8. Resultado de predicción parte 2	91
4.9. predicción caso 2	93
4.10. Resultado de predicción parte 1	93
4.11. Resultado de predicción parte 2	93

Índice de tablas

2.1. Análisis comparativo de artículos de investigación.	23
2.2. Propuesta de solución.	30
3.1. Descripción de variables lingüísticas	52
3.2. Parámetros de frecuencia cardíaca en niños de 12 a 18 meses.	53
3.3. Parámetros de QT corregido en niños menores de 15 años.	55
3.4. Riesgo de muerte subita cardíaca en edad pediátrica.	59
3.5. Descripción de Variables Lingüísticas	61
3.6. Tabla de reglas de inferencia del modelo de predicción por ECG	66
3.7. Extracto de reglas de inferencia del modelo de lógica difusa de datos clínicos	67
4.1. Datos de clasificación por probabilidad	79
4.2. Matriz de confusión	80
4.3. Resultado del modelo de predicción	80
4.4. Tabla de aportación al estado de la práctica.	94

Resumen

La muerte súbita cardíaca se refiere a la interrupción brusca e inesperada de las funciones cardiovasculares y puede ocurrir hasta una hora después de los primeros síntomas. En los niños, existen dos tipos de enfermedades que contribuyen a este padecimiento: las estructurales y las eléctricas. Lamentablemente, la falta de información sobre estos padecimientos, tanto entre los médicos generales como en la población general, dificulta su detección temprana, lo que resulta en un tratamiento tardío o incluso en la falta del mismo. Es por ello que el presente trabajo propone el desarrollo de un módulo de software basado en técnicas de inteligencia artificial, con el objetivo de realizar la predicción de muerte súbita cardíaca en niños. Este módulo predice el riesgo de padecer este trastorno a partir de datos clínicos y electrocardiogramas. Con su ayuda, los médicos contarán con una herramienta que sirva como apoyo para detectar de forma temprana el riesgo de muerte súbita cardíaca en niños, lo cual permitirá un diagnóstico y tratamiento oportunos. El beneficio principal de este módulo es la reducción del número de muertes infantiles por muerte súbita cardíaca en México.

Abstract

Sudden cardiac death refers to the abrupt and unexpected cessation of cardiovascular functions, which can occur within an hour of the onset of initial symptoms. In children, two types of conditions contribute to this phenomenon: structural and electrical disorders. Unfortunately, the lack of information about these conditions among both general practitioners and the broader population hinders early detection, often resulting in delayed or even absent treatment. This study proposes the development of a software module based on artificial intelligence techniques, aiming to predict sudden cardiac death in children. This module assesses the risk of this condition based on clinical data and electrocardiograms. With this tool, physicians will have support to help detect the risk of sudden cardiac death in children at an early stage, allowing for timely diagnosis and treatment. The primary benefit of this module is the potential reduction in the number of pediatric deaths due to sudden cardiac death in Mexico.

Introducción

La Muerte Súbita Cardíaca (MSC) es un padecimiento que afecta a millones de personas en el planeta y se demostró que es la causa del 20 % al 30 % de las muertes de origen cardíaco en personas adultas. 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”, lo que dificulta el registro y seguimiento de este 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. No obstante, la falta de conocimiento por parte de los médicos de primer contacto y las personas en general hacen 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 aprendizaje automático las más destacadas y en poca proporción la lógica difusa.

Esta tesis está dividida en cinco capítulos: el primero presenta el marco teórico, el planteamiento del problema, los objetivos generales y específicos, así como la justificación. El segundo capítulo se enfoca en el estado de la práctica y el análisis comparativo de las soluciones existentes. El tercer capítulo describe la metodología seguida para el desarrollo del proyecto, la arquitectura de la aplicación y el modelo de predicción de lógica difusa. En el capítulo 4 se muestran los resultados obtenidos tras el desarrollo de la aplicación Web y finalmente en el capítulo 5 se presentan las conclusiones y recomendaciones.

Capítulo 1

Antecedentes

En este capítulo, se dan a conocer los conceptos, términos y fundamentos que se utilizaron para este proyecto, asimismo se describe la problemática de manera general, objetivo general, objetivos específicos y justificación del trabajo.

1.1. Marco teórico

En esta sección se presentan las definiciones de los términos y tecnologías que se utilizaron para el presente trabajo.

1.1.1. Inteligencia artificial

La Inteligencia Artificial (IA) es un subtipo de la computación que se enfoca en la creación de instrumentos capaces de simular el proceso de inteligencia humana, lo que incluye el razonamiento, el aprendizaje y la auto-corrección. Para llevar a cabo estas tareas, las máquinas utilizan diferentes algoritmos, que permiten la toma de decisiones basadas en un proceso lógico y jerárquico, el cual es reproducido en un lenguaje que las máquinas interpretan y ejecutan con mayor eficiencia que el ser humano.

Una de las principales ventajas de la IA es que, a diferencia de los seres humanos, las máquinas no se cansan y no tienen necesidades fisiológicas que les obliguen a interrumpir su trabajo, lo que les permite aprender y procesar información de forma más rápida y eficiente [1].

La Inteligencia Artificial tiene múltiples aplicaciones en diversos campos, como por ejemplo en la medicina, donde se utiliza como apoyo para el diagnóstico médico y el seguimiento de los pacientes. Gracias a la capacidad de procesamiento de datos de la IA, es posible analizar grandes cantidades de información clínica y médica, lo que facilita la identificación temprana de enfermedades y la toma de decisiones más precisas en cuanto al tratamiento y seguimiento de los pacientes.

Además, la IA también es utilizada en otras áreas, como la industria, el comercio, la seguridad, la robótica, entre otras. En la industria, por ejemplo, se utiliza para optimizar los procesos de producción, mejorar la calidad de los productos y reducir los costos de producción.

1.1.2. Lógica difusa

El concepto de Lógica Difusa lo propuso por Lofti A. Zadeh, profesor en la Universidad de Berkeley en California. En su propuesta, la lógica difusa se presentó como un enfoque para el procesamiento de información en el cual los datos pueden tener un grado de pertenencia parcial a conjuntos [3].

La lógica difusa aplicada en inteligencia artificial es un método de razonamiento que emula el pensamiento humano, permitiendo a las máquinas procesar información que puede ser incompleta o incierta. Este enfoque es característico de muchos sistemas expertos y se diferencia notablemente de la lógica booleana.

A diferencia de la lógica booleana, la cual clasifica las variables de manera estricta en categorías binarias como “verdadero” o “falso”, la lógica difusa permite una clasificación gradual. Esto significa que una variable puede pertenecer parcialmente a múltiples categorías simultáneamente, con diferentes grados de pertenencia. Un ejemplo práctico de esta diferencia se puede observar en la clasificación de la temperatura del agua. Mientras que la lógica booleana no considera estados de transición, clasificando el agua únicamente como “fría” o “caliente”, como se muestra en la figura ??, la lógica difusa permite representar estados intermedios utilizando grados de pertenencia, como se ilustra en la figura ??.

La lógica difusa, también conocida como lógica borrosa, es útil para gestionar sistemas mediante reglas basadas en el "sentido común", que se refieren a cantidades sin valores precisos definidos. En términos generales, la lógica difusa se aplica en sistemas de control

y modelización de sistemas continuos en campos como la ingeniería, la física, la medicina, la biología y la economía.




Figura 1.1 Lógica Booleana: El agua es clasificada como “fría” o “caliente” sin transiciones graduales.




Figura 1.2 Lógica Difusa: El agua puede ser “parcialmente fría” y “parcialmente caliente” con transiciones graduales.

1.1.3. Muerte súbita cardiaca

La muerte súbita cardíaca (MSC) se define como la muerte que se presenta de forma espontánea por una falla general en el sistema cardiovascular en un lapso que se encuentra entre la primera hora de comenzar los síntomas iniciales. En la mayoría de las ocasiones ocurre por anormalidades de origen cardiovascular, cuando la MSC afecta a un infante con menos de un año se le atribuye el término de muerte súbita infantil (MSI) [4].

La MSC es un acontecimiento que ocurre de forma imprevisible y que impacta de forma general a la población. En México no se reporta un registro oficial de MSC pediátrico y cuando ocurre en su mayoría se catalogan como muertes por causas no conocidas o mal definidas.

La MSC en niños se dividen en dos grupos de enfermedades: (a) enfermedades de origen estructural. (b) enfermedades que afectan el sistema eléctrico del corazón. Los padecimientos estructurales que se asocian a MSC son en las cuales se identifica una anomalía de carácter anatómico y en la mayoría de las ocasiones llegan a diagnosticarse por medio de un ecocardiograma. Estas malformaciones causan arritmias malignas. Por otra parte, el segundo grupo de enfermedades eléctricas que ocasionan MSC, están constituidas por una o varias anomalías en el ritmo eléctrico en el corazón que se encuentran presente en un corazón estructuralmente normal, los padecimientos que predisponen a la MSC infantil se observan en la figura 1.3.




Figura 1.3 Enfermedades que predisponen la MSC en niños

1.1.4. Electrocardiograma

La Organización Mundial de la Salud (OMS) considera que el electrocardiograma (ECG) es una técnica diagnóstica no invasiva, económica y muy útil en el diagnóstico de enfer-

medades cardíacas. Este procedimiento registra la actividad eléctrica del corazón en un papel milimetrado de manera sencilla, segura y eficiente [5].

El ECG tiene múltiples aplicaciones, entre ellas, la identificación de alteraciones en el ritmo cardíaco, el sistema de conducción, la isquemia y los infartos de miocardio, así como alteraciones en la excitabilidad relacionadas con cambios en la concentración de electrolitos y efectos de medicamentos. Además, proporciona información sobre la anatomía del corazón, como en el caso de la insuficiencia cardíaca, que es originada por el aumento de tamaño.

Los miocitos son células musculares estriadas que se contraen por la presencia de proteínas como actina y miosina que forman parte de la unidad contráctil del músculo llamada sarcómera. Los miocitos adyacentes están unidos por discos intercalares que permiten la transmisión de estímulos eléctricos, lo que explica el funcionamiento del músculo cardíaco como un sincitio. Además de las células contráctiles del corazón, existen células especializadas en la generación y conducción de los estímulos eléctricos a través de todo el miocardio.

1.1.5. Arritmia cardíaca

Una arritmia cardíaca se refiere a una irregularidad en la frecuencia o ritmo de los latidos del corazón. Esta afección se presenta en un latido demasiado rápido, demasiado lento o con un patrón de ritmo anormal [6].

Estas irregularidades tienen diversas causas, grados de severidad y consecuencias médicas. Algunos cambios en el ritmo cardíaco desaparecen de forma espontánea o al eliminar el factor desencadenante, mientras que en otros casos afectan significativamente la función cardíaca. Este estudio explora las características del sistema de conducción del corazón involucrado en las arritmias, los diferentes tipos de irregularidades presentes y las principales estrategias terapéuticas empleadas para combatirlas [7].

1.1.6. Miocardiopatía hipertrófica

La miocardiopatía hipertrófica es una enfermedad hereditaria del sistema cardiovascular muy común [8]. Su característica principal está asociada al engrosamiento de las paredes del ventrículo y tiene un manejo clínico muy complejo por la gran variedad de presentaciones clínicas, las diferentes manifestaciones fenotípicas, el gran número de mutaciones causales y su amplia variedad de manifestaciones fenotípicas, gran cantidad de mutaciones causales y un amplio espectro de complicaciones asociadas. En un alto porcentaje de los casos, las mutaciones en las proteínas sarcoméricas son la causa subyacente, llegando a ser responsables de hasta el 60 % de los casos.

La sintomatología de esta enfermedad incluye dolor torácico, disnea, síncope y palpitaciones, los cuales se relacionan con el inicio de disfunción diastólica, obstrucción del tracto de salida del ventrículo izquierdo, isquemia, fibrilación auricular y respuesta vascular inadecuada. Además, aumenta el riesgo de sufrir muerte súbita, insuficiencia cardiaca y eventos tromboembólicos.

1.1.7. Fibrilación ventricular

La fibrilación ventricular es una arritmia ventricular maligna que se caracteriza por una activación desorganizada y parcelar del ventrículo. En esta condición, el ciclo eléctrico de corazón es caótico, y la muerte del paciente ocurre si esta condición no es revertida inmediatamente [9]. La fibrilación ventricular es causante del 75 % de las muertes súbitas y se observa con mayor frecuencia en pacientes con cardiopatía isquémica, especialmente en el caso de un infarto agudo de miocardio. En estos pacientes, este tipo de arritmia es la más habitual y la causa principal de mortalidad.

La fibrilación ventricular también es la causa de muerte súbita en pacientes sin cardiopatía orgánica subyacente, aunque es menos común. En algunos casos, la fibrilación ventricular es el resultado de una alteración de contenido de electrolitos en el cuerpo, una intoxicación farmacológica, como la causada por la digital. Las características electrocardiográficas de la fibrilación ventricular incluyen ondas P indeterminables, relación AV no reconocidas, complejos QRS reemplazados por ondas irregulares de magnitud y forma

variable, y una frecuencia entre 150 y 500 latidos por minuto con intervalos RR de forma irregular.

1.1.8. Metodología UWE

UWE(*UML-based Web Engineering*, Ingeniería web basada en UML) es un enfoque basado en estándares para la ingeniería de aplicaciones web, proporcionando una notación específica de dominio, un proceso de desarrollo basado en modelos y soporte de herramientas. UWE es su enfoque basado en estándares, que va más allá de la utilización del Lenguaje Unificado de Modelado (UML).

UWE utiliza notación UML y tipos de diagrama UML siempre que sea posible para el análisis y diseño de aplicaciones web. Sin embargo, para características específicas de la web, como nodos y enlaces de estructuras de hipertexto, el perfil de UWE introduce estereotipos, valores etiquetados y restricciones definidas para los elementos de modelado. Esta extensión cubre aspectos clave como la navegación, la presentación, los procesos de negocio y los aspectos de adaptación. En conjunto, la notación UWE se concibe como una extensión ligera de UML.

1.2. Situación tecnológica, económica y operativa de la empresa

El Hospital Infantil Federico Gomez es una institución pública especializada en la atención de la salud infantil, que se ubica en la Ciudad de México, en la Calle Doctor Márquez 162, Delegación Doctores, Cuauhtémoc. Con una trayectoria de más de 70 años, el hospital se ha convertido en un referente nacional en el cuidado y tratamiento de pacientes pediátricos, ofreciendo servicios de alta calidad en más de 140 especialidades y subespecialidades médicas, incluyendo principalmente las áreas de neonatología, oncología, nefrología, infectología, medicina interna, terapia intensiva, cardiología, neurología, endocrinología y cirugía.

El personal médico del hospital está altamente capacitado y trabaja de manera interdisciplinaria para brindar un enfoque integral en el tratamiento de cada paciente, garantizan-

do la mejor atención médica posible. La institución cuenta con tecnología de vanguardia y modernas instalaciones, lo que garantiza un ambiente seguro y cómodo para pacientes y visitantes.

El Hospital Infantil Federico Gomez también se destaca por su importante labor de investigación, con más de 100 médicos pertenecientes al Sistema Nacional de Investigadores (SNI) que desarrollan más de 350 líneas de investigación. Este trabajo contribuye al avance de la medicina pediátrica y mejora constante de los tratamientos y cuidados que se ofrecen en la institución.

1.3. Planteamiento del problema

La MSC es la muerte inesperada que ocurre en una persona que incluso una hora antes del evento lucía en buenas condiciones o aparentemente sana. Las causas de la MSC se originan principalmente por dos arritmias cardíacas letales: la taquicardia (donde los ventrículos se contraen rápidamente y de forma anormal) y la fibrilación ventricular (donde el corazón se contrae rápida y caóticamente) [10].

De acuerdo con diversos estudios [4], la MSC provoca la muerte de 350 mil personas al año solo en EE. UU. y el número a nivel mundial oscila entre 4 y 5 millones de personas. En México, aunque no se tienen estadísticas confiables a causa de que los registros no se hacen de forma correcta [4], [11], es factible considerar que la prevalencia es similar a la de EE. UU. Para el caso de la población infantil en México, se tienen categorizadas en dos grupos las principales enfermedades causantes de la MSC.

La comunidad general y médica tienen poco conocimiento sobre las enfermedades que predisponen a la MSC en los niños. El registro de muertes en edad pediátrica con «causas desconocidas» sugiere que muchos niños fallecen de MSC sin ser diagnosticados con esta enfermedad de origen cardíaco. Una meta importante para mejorar la salud en la edad pediátrica es desarrollar estrategias que permitan reducir significativamente los casos de MSC en los niños.

La literatura especializada en enfermedades del corazón reporta algunos esfuerzos aplicando técnicas de IA [12], [13], y específicamente trabajando con el algoritmo Naïve Bayes [14], para identificar pacientes potenciales con MSC, pero no son estudios que consideren el contexto mexicano y menos a la población de niños.

Por estos motivos la presente propuesta se plantea desarrollar un módulo de software que realice la predicción de muerte súbita cardíaca en niños utilizando técnicas de inteligencia artificial.

1.4. Objetivo general y objetivos específicos

En esta sección se detallan los objetivos generales y específicos para resolver el problema planteado.

1.4.1. Objetivo general

Desarrollar un módulo de software para el apoyo a la predicción de riesgo de muerte súbita cardíaca en niños mediante técnicas de inteligencia artificial

1.4.2. Objetivos específicos

- Revisar el estado de la práctica en el contexto de predicción de muerte súbita cardíaca mediante técnicas de inteligencia artificial.
 - Analizar las tecnologías, algoritmos y métodos más utilizados para la predicción de muerte súbita cardíaca.
 - Definir un modelo de predicción de muerte súbita cardíaca en niños utilizando técnicas de inteligencia artificial.
 - Desarrollar un módulo de software considerando el *back-end* y *front-end* de acuerdo con el tipo de solución.
 - Evaluar el módulo desarrollado mediante un caso de estudio como prueba de concepto.
-

1.5. Justificación

La MSC es la muerte que se da de forma repentina por un colapso del sistema cardiovascular en un rango de tiempo de una hora del inicio de los primeros síntomas, en gran medida la causa es por anomalías en el sistema cardíaco. En México no se reportan cifras específicas sobre este padecimiento en edad infantil, ya que no se cuenta con un organismo que lleve el conteo de estas estadísticas. En 2015, el INEGI [15] reportó 3,842 decesos por causas no definidas (R95-R99), de estos números 514 corresponden a MSC.

Las enfermedades que están asociadas a la MSC en niños se clasifican en dos grupos: (1) enfermedades de tipo estructural, (2) enfermedades origen eléctrico. Las enfermedades asociadas al primer grupo se trata de padecimientos en los cuales está presente una malformación congénita del corazón, la cual causa arritmias malignas y el segundo grupo corresponde al funcionamiento anormal del ritmo eléctrico que se origina en el corazón y que se presenta en un corazón normal de forma estructural.

Por ese motivo, son necesarias herramientas que permitan la detección de forma temprana en la población infantil para dar un tratamiento oportuno y evitar la muerte inminente. Bajo estas condiciones, la presente propuesta se basa en desarrollar un módulo de software que permita la predicción de muerte súbita cardíaca en la población infantil utilizando técnicas de inteligencia artificial, sirviendo como apoyo a los doctores en la toma de decisiones.

Capítulo 2

Estado de la práctica

En esta sección resume los trabajos de investigación más relevantes que están relacionados, directa o indirectamente, parcial o totalmente, con la tesis propuesta.

2.1. Trabajos relacionados

En [16] las enfermedades cardíacas son unas de las principales causas de muerte en todo el mundo. En la mayoría de los casos, estas enfermedades contribuyen a que una persona padezca muerte súbita cardíaca, ya que los síntomas asociados a estas enfermedades no son fáciles de identificar. Sin embargo, muchas investigaciones aportan material significativo para su detección temprana. Bajo estas condiciones, los autores propusieron un modelo de lógica difusa utilizando el método Tsukamoto para la detección de riesgo de enfermedades cardíacas. Utilizando como valores de entrada once variables, entre ellas se encuentra el nivel de colesterol, presión arterial y datos de electrocardiogramas. Los valores de salida indican si una persona es saludable o tiene un grado bajo, medio o alto de riesgo.

El proceso para la creación del modelo constó de cuatro etapas: revisión de la literatura, diseño de un sistema difuso de inferencia, aplicación del modelo de lógica difusa de Tsukamoto y realización de la evaluación de resultados. La investigación llegó a la conclusión de que el método de Tsukamoto de lógica difusa es factible para la implementación de un modelo de riesgo de enfermedades cardíacas, aunque hasta ese momento de su investigación alcanzó una precisión del 58 %.

En [17] las enfermedades coronarias se catalogan como una de las principales causas de muerte en todo el mundo, incluida India. Los factores preponderantes de riesgo para esta enfermedad, especialmente en India, incluyen tabaquismo, diabetes, colesterol sérico, hipertensión y factores genéticos, entre otros. En este contexto, los autores proponen un modelo de predicción de riesgo de arritmias cardíacas mediante una combinación de lógica difusa y redes neuronales. Las variables de entrada utilizadas fueron siete, entre las cuales se encuentran el colesterol, la presión arterial, la actividad física, el tabaquismo, la edad, el índice de masa corporal y la diabetes. La variable de salida indica el nivel de presencia de la enfermedad cardíaca en las categorías de saludable, etapa temprana y avanzada. El número de reglas fue determinado mediante pruebas unitarias, y el número óptimo de reglas en el modelo se estableció en 44. El modelo resultante logró una precisión del 99.3 % en la detección de enfermedades coronarias, superando a los algoritmos clásicos de clasificación como SVM y KNN.

En [18] L. J. Muhammad et al. mencionaron que un sistema experto basado en inteligencia artificial imita la toma de decisiones de la misma manera que lo haría un ser humano y sirve como herramienta de apoyo para el diagnóstico de diversas enfermedades, como el COVID-19, el cáncer y las enfermedades cardíacas, entre otras. El enfoque de los autores se centró en las enfermedades coronarias debido a su alta mortalidad en todo el mundo. En este estudio, se propuso el desarrollo de un sistema experto aplicando lógica difusa para respaldar el diagnóstico de enfermedades coronarias en Nigeria.

Para el desarrollo, se utilizó el algoritmo C4.5 para la creación de una base de conocimientos debido a su rápida implementación. Se emplearon 12 variables de entrada, como edad, presión arterial, glucosa, colesterol, triglicéridos, creatinina, índice de masa corporal, ritmo cardíaco, entre otras. La variable de salida fue el diagnóstico de riesgo, categorizado como bajo, medio, moderado y severo. El sistema logró una precisión máxima del 94.55 %, una sensibilidad del 95.35 % y una especificidad del 95 %.

En [19] el infarto al corazón se presenta como una de las enfermedades más letales a nivel mundial, dada su elevada tasa de mortalidad. Hasta el momento, las medidas de salud implementadas no han resultado óptimas para reducir las muertes asociadas a este padecimiento. El propósito principal de este estudio fue anticipar la ocurrencia de infartos cardíacos a través de factores determinantes. Con este fin, se diseñó un modelo de lógica difusa que incorpora parámetros como la edad, género, niveles de colesterol, concentra-

ción 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 fue del 41.9 %.

En [20], los autores determinaron los factores relacionados con eventos de arritmias peligrosas en un estudio multicéntrico que involucró a un total de 13 instituciones. Los eventos bajo investigación abarcaban un período desde 1980 hasta 2010.

En este estudio se incluyeron a 72 pacientes con Tetralogía de Fallot (TOF) que habían experimentado un paro cardíaco documentado, en su mayoría asociado con taquicardia ventricular sostenida, una arritmia vinculada a la muerte súbita cardíaca. Los datos utilizados comprendieron historias clínicas y quirúrgicas, electrocardiogramas, información demográfica, radiografías de tórax, pruebas de esfuerzo y ecocardiogramas. Estos datos fueron normalizados, teniendo en cuenta factores como la categorización de las reparaciones quirúrgicas en cinco tipos según su complejidad. Las variables continuas se analizaron para verificar la normalidad de su distribución.

Para el modelo de riesgo, se utilizó la puntuación de importancia de las variables en el modelo de random forest y la clasificación de variables en el árbol de decisiones. Se aplicó un factor de importancia proporcional basado en el índice de Gini a cada variable, lo que permitió categorizar a los pacientes con TOF en grupos de riesgo de muerte súbita cardíaca o eventos de arritmias potencialmente mortales, dividiéndolos en grupos de bajo, medio, alto y muy alto riesgo. Los resultados finales de esta técnica mostraron una sensibilidad del 54 % (IC del 95 %: del 44 % al 63 %) y una especificidad del 86 % (IC del 95 %: del 83 % al 89 %).

Los autores afirmaron que este enfoque de estratificación de riesgo, basado en la información de historias médicas y pruebas no invasivas, permite categorizar a los pacientes con TOF en grupos de alto riesgo de arritmia maligna.

En [21] Rodríguez et al. señalaron que las enfermedades cardiovasculares son las causas más comunes de fallecimiento en las personas. Sin embargo, la identificación temprana de pacientes con un alto riesgo de muerte súbita cardíaca (MSC) sigue siendo un desafío en la actualidad. El objetivo principal de su estudio fue emplear el análisis de la

variabilidad de la frecuencia cardíaca (VFC) y la variabilidad de la frecuencia arterial (VFA) con el propósito de introducir nuevos indicadores de estratificación de riesgo no invasivos en pacientes con miocardiopatía dilatada idiopática (IDC).

Para llevar a cabo esta investigación, se utilizaron datos de electrocardiogramas de alta resolución y mediciones de presión arterial continua no invasiva en un grupo de 91 pacientes con IDC y 49 pacientes sanos. Los datos de ECG formaron parte del estudio German ART (Ensayo de Regulación Autonómica) que tenía como objetivo evaluar los factores predictivos de riesgo de MSC. Se empleó un sistema Porti (TMSi BV, Países Bajos) para las grabaciones de ECG y un monitor Portapress NIBP (TNO Biomedical Instrumentation, Ámsterdam, Países Bajos) para las mediciones de presión arterial.

Los pacientes fueron clasificados en grupos según su probabilidad de experimentar una muerte súbita cardíaca (MSC). Se consideraron en el grupo de alto riesgo (IDCHR) a aquellos que, después de dos años, fallecieron o experimentaron complicaciones graves con riesgo de vida. Por otro lado, se ubicaron en el grupo de bajo riesgo (IDCLR) a los pacientes que se mantuvieron estables durante ese período.

Además, se desarrollaron modelos de Máquinas de Vectores de Soporte (SVM) con el propósito de categorizar a estos pacientes según su probabilidad de sufrir una muerte súbita cardíaca (MSC). En conclusión, el modelo logró una precisión del 94,4

En [22] Lyon et al. describieron la relación entre la arritmia ventricular y la muerte súbita cardíaca en pacientes con Miocardiopatía Hipertrófica (HCM). Hasta ese momento, no se habían utilizado biomarcadores electrofisiológicos para evaluar el riesgo en esta enfermedad. Por lo tanto, el objetivo de su investigación consistió en identificar diferentes perfiles de HCM mediante el análisis de grabaciones de 30 minutos de electrocardiogramas (ECG) y determinar las diferencias en los factores de riesgo clínico utilizando imágenes de resonancia magnética.

Para llevar a cabo el estudio, se recopilaron datos de un holter de 12 derivaciones de 85 pacientes con HCM y 38 pacientes sanos. Se aplicó un modelo matemático y un enfoque de agrupación asistida por computadora para identificar subgrupos de fenotipos.

En el análisis de ECG, se asignaron marcadores morfológicos a las ondas QRS y T. Se seleccionaron siete características relevantes mediante un algoritmo de supervisión de características no supervisado para reducir la cantidad de variables. Luego, se utilizó

el algoritmo DBSCAN (Density-Based Spatial Clustering of Applications with Noise) para extraer subgrupos. Además, se llevó a cabo un análisis de agrupamiento basado en la morfología del complejo QRS utilizando un enfoque conocido como KNN, gracias a este enfoque, el modelo logró identificar cuatro perfiles distintos de HCM.

En [23] se investigó el papel de las arritmias ventriculares, una de las causas comunes de muerte en Estados Unidos. Los autores exploraron cómo la transición del tejido cardíaco sano a una cicatriz contribuye a la formación de un sustrato complejo propenso a arritmias ventriculares.

El estudio se llevó a cabo con 122 pacientes que padecían insuficiencia cardíaca y una función ventricular izquierda deteriorada. Se utilizó resonancia magnética cardíaca para analizar la estructura del ventrículo izquierdo. Se desarrolló una nueva técnica para evaluar la regularidad de las señales del corazón y crear un perfil de complejidad espacial. Posteriormente, se aplicó un algoritmo de aprendizaje automático para identificar qué perfiles se relacionaban con eventos de arritmia durante un seguimiento de 5 años.

Los resultados mostraron que el algoritmo de aprendizaje automático logró una precisión general del 81 % y acertó en el 86 % de los casos en los que no se produjeron arritmias ventriculares. El valor predictivo negativo alcanzó el 91 %. Además, se observó que la puntuación de complejidad promedio (CS) fue significativamente mayor en pacientes que experimentaron arritmias ventriculares en comparación con aquellos que no las tuvieron ($0,5 \pm 0,5$ frente a $0,1 \pm 0,2$; $p < 0,0001$). También se encontró una relación independiente entre la puntuación de complejidad (CS) y los eventos de arritmia ventricular en un modelo de regresión multivariable (relación de riesgo = $1,5 [1,2-2,0]$; $p = 0,002$).

En [24] Nakajima et al. mencionaron que en pacientes con Insuficiencia Cardíaca Crónica (ICC), las causas de muerte se centraron cada vez más en la muerte súbita cardíaca, un fenómeno clínico de gran relevancia. Además, subrayaron que investigaciones recientes resaltaron la necesidad apremiante de mejorar los modelos de estratificación de riesgos para orientar estrategias de manejo basadas en la evaluación precisa del riesgo individual.

En respuesta a esta necesidad, los autores se dedicaron a crear un modelo de predicción utilizando datos de pacientes con un seguimiento de 2 años después de haber sido

diagnosticados con ICC. Esta cohorte de pacientes consistió en 526 individuos, con una edad promedio de 66 ± 14 años. El modelo se entrenó con un conjunto de 13 variables clínicas, entre las que se incluyeron la edad, el género, la clase funcional según la Asociación del Corazón de New York (NYHA), y la fracción de eyección del ventrículo izquierdo, entre otras relevantes.

Las curvas ROC, basadas en regresión logística y utilizadas para calcular las probabilidades de eventos, arrojaron valores de AUC impresionantes: 0,88 para todos los eventos, 0,92 para ICC y 0,80 para eventos arrítmicos (ArE). Estos resultados sugieren que el modelo desarrollado por los autores fue altamente efectivo en la predicción de eventos en pacientes con ICC, destacando su utilidad en la estratificación de riesgos.

En [25] mencionan que el trastorno del ritmo cardíaco origina enfermedades cardíacas severas, lesiones en otros órganos, por ejemplo, el cerebro, los riñones y hasta incluso muerte súbita cardíaca. La forma más común de detectar arritmias cardíacas es utilizando el electrocardiograma. Sin embargo, para el diagnóstico correcto es necesario tener en cuenta más información sobre el paciente, por ejemplo, sexo, edad, peso, entre otros atributos. Algunas técnicas aplicadas para la clasificación de arritmias utilizadas son: *Naive Bayes*, *KNN*, *Decision Tree* y *SVM*.

Antes de aplicar algún método de clasificación se lleva a cabo un proceso para limpiar el conjunto de datos de atributos irrelevantes y que interfieren en la información utilizando métodos de selección y construcción de características. El objetivo del trabajo fue generar un conjunto reducido de atributos para clasificar adecuadamente los datos de los electrocardiogramas utilizando programación *kayzen* y programación lineal genética como apoyo para aumentar la precisión en el algoritmo de clasificación de RF.

Después realizar varias comparaciones concluyeron en que el RF con características construidas por la PK, proporciona una mejora de rendimiento predictivo que otros métodos investigados.

En [26] El-Geneidy et al. Propusieron un sistema de predicción para muerte súbita cardíaca para pacientes con insuficiencia cardíaca clase II y clase III de la NYHA (New York

Heart Association, Asociación del Corazón de Nueva York) en el cual aplicaron el modelo de riesgo de Cox y el algoritmo Extra-Tress para predecir si un paciente sufriría muerte súbita cardíaca. La base de datos para el entrenamiento fué SCD-HeFT (Sudden Cardiac Death in Heart Failure Trial, Muerte súbita cardíaca en ensayo de insuficiencia cardíaca) cuenta con información de 1692 personas y a causa del proceso de filtrado, determinaron utilizar solo la información de 168 personas para el proceso de clasificación de 180 días y 580 personas para el proceso de clasificación de 365 días. El modelo utilizado se validó por el método *k-fold cross-validation* con $k=5$, los resultados arrojaron un valor de puntuación $f1$ de 0.9607 en 180 días de predicción y un valor de puntuación de $f1$ de 0.9607 para 365 días.

En [27] los autores propusieron el desarrollo probado y validado de un modelo de regresión logística para la predicción de muerte súbita cardíaca y paro cardíaco no fatal en adultos con ACHD (Adult Congenital Heart Disease, Cardiopatías Congénitas en Adultos), el modelo de riesgo y las predicciones de riesgo se realizaron mediante un modelo de regresión logística utilizando una cohorte previamente informada de 3311 pacientes con ACHD en el Hospital Universitario La Paz en Madrid, España. Para el entrenamiento del modelo se utilizaron datos de 18 centros adscritos a la red ACHD española y para la validación datos de otros dos centros, para el proceso de selección de variables se realizó un análisis de variables clínicas relevantes como complejidad de la enfermedad, datos demográficos, intervenciones previas, síntomas, eventos arrítmicos, morbilidad asociada, datos del electrocardiograma más reciente, radiografía de tórax, holter, pruebas de refuerzo, entre otros. Se utilizó regresión no lineal para calcular las probabilidades previstas en el conjunto de datos, todos los análisis se realizaron bajo el lenguaje R (V.3.6) ampliado con paquetes apropiados.

En [28] Fujita, H. et al. mencionaron que la muerte súbita inesperada con antecedentes conocidos y no conocidos de enfermedades cardíacas se clasifica como muerte súbita cardíaca, en Estados Unidos aproximadamente 1 de cada 1000 adultos mayores de 35 años tienen predisposición a esta enfermedad, además mencionaron que se ha demostrado que los métodos de predicción lineal se utilizan para el análisis de HRV (Heart Rate Variability, Variabilidad del ritmo cardíaco), la dispersión del intervalo QT, entre otros. Por

este motivo presentaron una metodología para clasificar a personas con predisposición a muerte súbita cardíaca mediante uso de técnicas no lineales, para entrenar el modelo se utilizó la base de datos de acceso abierto MIT-BIH SCD y la base de datos Normal Sinus Rhythm (Ritmo sinusal normal) las características no lineales de este trabajo utilizadas fueron: REnt, FE, parámetro de Hjorth (Actividad, movilidad y complejidad), TEnt y características de energía de los coeficientes DWT. Para la clasificación se utilizaron los algoritmos DT, KNN y SVM. Todo el procedimiento se aplicó a señales HRV de segmentos de intervalos de uno a cuatro minutos por separado para personas normales y con muerte súbita cardíaca.

En [29] un electrocardiograma es una herramienta utilizada en el diagnóstico de padecimientos cardíacos, mediante ella se detecta la irregularidad de señales del corazón, ya que estudia señales eléctricas y musculares asociadas al corazón, de esta forma se facilita la detección de anomalías en el funcionamiento del músculo cardíaco, mediante la frecuencia cardíaca se detectan diferentes categorías de enfermedades entre ellas las arritmias (latidos irregulares del corazón). Los autores propusieron una metodología para la clasificación de arritmias cardíacas con resultados precisos en un tiempo computacional bajo utilizando el clasificador SVM (Support Vector Machine, Máquina de Vectores de Soporte) y La transformada Wavelet discreta. En el trabajo presentado se utilizaron tres clases diferentes de arritmia: ritmo sinusal normal, insuficiencia cardíaca congestiva y arritmia cardíaca de los bancos de datos MIT-BIH y BIDMC. Haciendo uso de la transformada de Wavelet se extrajeron 190 características de datos y fueron enviados al algoritmo SVM para su clasificación. La precisión obtenida en este modelo fue de 95.2

En [30] se menciona que el corazón es el órgano más vital para el ser humano se utilizan varias técnicas para medir la frecuencia cardíaca y una de ellas es el electrocardiograma. Los autores mencionan que una de las causas más frecuentes asociadas al ataque al corazón son problemas relacionados al estilo de vida, hábitos de sueño irregulares, problemas psicológicos, falta de actividad física, entre otros. Este problema ya no solo lo presentan personas adultas también aparece en los niños por la tendencia de estilo de vida actual. Los autores indicaron que en su estudio ofrece una manera eficiente de probar la combinación de tres conjuntos de datos utilizando variables clínicas, de electro-

cardiogramas y parámetros clínicos únicos de cada persona y determinaron que el método utilizando de forma simultanea estos tres conjuntos es eficiente para realizar la predicción de un ataque al corazón, para probar el conjunto de datos se utilizó un red neuronal probabilística (PNN) y el modelo de análisis de árbol de clasificación y regresión (CART) para hacer una predicción del estado actual del paciente. La precisión obtenida utilizando el conjunto de datos combinado (datos clínicos y electrocardiogramas) para la clasificación fue de 95 % en comparación de únicamente datos clínicos 86 % y electrocardiogramas 80 %.

En [31] Devi, R et al. mencionaron que la muerte súbita cardíaca es el resultado de una actividad cardíaca irregular o interrumpida, se estima que 7 millones de personas pierden la vida a causa de este padecimiento de forma anual, los estudios de origen epidemiológico indican que los orígenes de MSC incluyen enfermedad de las arterias coronarias, cardiomiopatías, anomalías electro-fisiológicas, cardiopatía valvular, entre otros padecimientos. Por este motivo encontrar las irregularidades cardíacas en etapas tempranas es de suma importancia para llevar un correcto tratamiento y evitar la MSC. Bajo estas premisas los autores proponen un modelo para predecir la MSC una hora antes de su incidencia utilizando un análisis de variabilidad de frecuencia y el clasificador KNN.

En [32] Manhong Shi et al. Mencionan que la MSC es un factor que ocasiona la muerte en una persona en cuestión de minutos, por esta razón es de suma importancia obtener información temprana para pacientes que estén en riesgo de MSC especialmente personas que se encuentren fuera de algún hospital. En este estudio los autores propusieron un método de predicción de MSC utilizando EEMD (*Ensemble Empirical Mode Decomposition*, Descomposición De Modo Empírico de Conjunto) en la HRV (*Heart Rate Variability*, Variabilidad de Frecuencia Cardíaca) para descomponerlos en IMFs (*Intrinsic mode functions*, Funciones de Modo Intrínseco) al igual que la utilización de cinco parámetros de entropía, entropía Rényi (RenEn), entropía difusa (FuEn), entropía de dispersión (DisEn), la entropía de permutación multiescala mejorada (IMPE) y entropía de distribución Renyi (RdisEn), se calcularon a partir de los primeros cuatro IMFs aplicado a 14 minutos (7 intervalos sucesivos de 2 minutos) de HRV. La fuente de datos utilizada en este proyecto fue PhysioBank MIT BIH (*Normal Sinus Rhythm*, Ritmo Sinusal Normal) y MIT/BIH SCD (*Sud-*

den Cardiac Death, Muerte cardíaca súbita) y el algoritmo utilizado para la clasificación fue KNN con una precisión promedio del 94.7 % 14 minutos antes del suceso.

En [33] un episodio de MSC se produce cuando la conductividad del corazón cambia, provocando una circulación sanguínea no adecuada para el correcto funcionamiento de los órganos vitales, si esta condición no se atiende oportunamente pone en riesgo la vida de la persona que la padece. Existen distintas causas que generan la MSC por ejemplo la asistolia, taquicardia ventricular, fibrilación ventricular, entre otras. Por esta razón los autores dieron a conocer una nueva metodología para la predicción de eventos de MSC, utilizando como primer paso el método de descomposición empírico (EMD) con el cual separa la señal del ECG (electrocardiograma) en un conjunto de bandas de frecuencia, el segundo paso es emplear un conjunto de índices de entropía para examinar las bandas de frecuencia obtenidas, con el fin de estimar las características que se emplearán para la predicción de MSC, como tercer paso las características más discriminantes se eligen mediante un análisis de varianza (ANOVA) y como cuarto paso las características seleccionadas se clasifican empleando una red neuronal de percentron multicapa. Con el fin de predecir un episodio de MSC 25 minutos antes del suceso con una precisión del 94 %. Las bases de datos utilizadas en este trabajo fueron MIT/BIH-SCDH con datos de 20 pacientes con MSC y MIT/BIH-NSR 18 pacientes normales.

En [34] los autores mencionaron que la mayoría de las investigaciones de la predicción de MSC basadas en HRV se han enfocado en eventos de MSC que ocurren en los intervalos de seguimiento de largo plazo (al menos un año) y han utilizado índices de HRV extraídos de grabaciones de al menos 24 horas, su estudio se enfocó en desarrollar un modelo utilizando SVM para la predicción de MSC basándose en combinaciones de índices de HRV y de huella cardíaca. Para entrenar el modelo utilizaron un *dataset* de series de tiempo RR basados en grabaciones de corto plazo (1000 latidos del corazón) mientras el otro conjunto para probar el rendimiento, se midieron once índices de HRV y cinco índices de huellas cardíacas de 135 pares de grabaciones, a través de la validación cruzada de 10 veces, se identificó el mejor valor de la curva. La precisión obtenida del modelo fue entre 80 y 86 % en fase de entrenamiento y en fase de validación fue de 67 %.

En [35] los autores mencionaron lo importante que es de generar una estrategia adecuada para gestionar las características extraídas para la correcta clasificación de la MSC el enfoque de la investigación fue la selección de subconjuntos de características locales a través procesos no lineales, de frecuencia de tiempo y clásicos extraídos de un rango de intervalos de un minuto hasta llegar a los 13 minutos de predicción. Por lo tanto, los autores mencionaron que fueron seleccionadas las mejores características de predicción que difieren entre sí en cada minuto antes del incidente. Para la clasificación de MSC se utilizaron los algoritmos KNN, SVM, ME y MLP, la clasificación de la Mezcla de Expertos produjo una discriminación de clase más precisa que otros clasificadores conocidos. El rendimiento del método propuesto se evaluó utilizando la base de datos MIT-BIH, que condujo a una sensibilidad, especificidad y precisión de 84,24 %, 85,71 % y 82,85 %, respectivamente, durante trece minutos.

En [36] Bhattacharya M et al. Propusieron la utilización de variables clínicas para la evaluación de un modelo de aprendizaje automático basado en datos que considera una gama de atributos múltiples para la clasificación de arritmias ventriculares (ArV) que conducen a muerte súbita cardíaca. Para este estudio utilizaron el historial clínico de 711 pacientes con miocardiopatía hipertrófica, de los cuales se etiquetaron 61 con arritmias ventriculares y los restantes (650) como pacientes sin arritmias ventriculares. Inicialmente, se seleccionaron 93 variables clínicas, pero en el proceso de análisis de asociación de variables determinaron que solo 22 variables resultaron importantes para la predicción de ArV.

La metodología que aplicaron consta de cinco pasos siendo: 1) preprocesamiento para eliminar variables no asociadas con ArV; 2) selección de características para identificar variables clínicas más informativas para separar los casos de Arv y no ArV; 3) análisis de asociación para identificar el grado de asociación entre cada variable predictora y la clase ArV; 4) aplicación de técnicas de aprendizaje automático supervisado para realizar la clasificación; y 5) evaluación cuantitativa y cualitativa para evaluar el desempeño del clasificador.

Para el estudio utilizaron datos recolectados de Centro de Excelencia de Miocardiopatía Hipertrófica de Johns Hopkins entre 2005 y 2015. Estos datos clínicos incluyen, síntomas, medicamentos, comorbilidades, antecedentes de arritmias, análisis de electrocardiogramas, entre otros. Durante el proceso de entrenamiento notaron un bajo rendimiento por el desequilibrio de datos, ya que los datos de pacientes sin ArV fueron mayores, para solventar este problema utilizaron métodos de sobremuestro y submuestreo. Los autores también mencionan que los algoritmos utilizados en su trabajo fueron: RL (Regresión logística), RF (Random Forest), Decision Tree y Naive Bayes para el entrenamiento de los clasificadores se utilizó la librería scikit-learn de Python, la precisión obtenida en su modelo fue de 0.73 % de sensibilidad y 0.76 % de especificidad.

2.2. Análisis comparativo

La tabla 2.1 presenta una comparación de los contenidos de los artículos investigados, de manera concreta se visualizan el problema que se encuentra, el enfoque de solución propuesto, los resultados y aportación tecnológica de los investigadores.

Tabla 2.1 Análisis comparativo de artículos de investigación.

Artículo	Problema	Técnica de IA	Resultados	Aportación
I. Iancu et al. [16].	Falta de un modelo de predicción de enfermedades cardíacas.	• <i>Lógica difusa.</i>	58 %	Generaron un modelo de predicción de enfermedades cardíacas
P. Kora et al. [17]	Falta de un modelo de predicción de enfermedades coronarias.	• <i>Lógica difusa.</i>	99.3 %	Lograron probar que el modelo de lógica difusa es viable para la detección temprana de factores para la predicción de enfermedades coronarias
L. J. Muhamad et al. [18]	Falta de un modelo de predicción de enfermedades coronarias en Nigeria.	• <i>Lógica difusa.</i>	94.55 %	Lograron predecir el riesgo de enfermedades coronarias con un alta precisión.
Continúa en la siguiente página				

Tabla 2.1 Análisis comparativo de artículos de investigación.

Artículo	Problema	Técnica de IA	Resultados	Aportación tecnológica
L. J. Muham-mad et al. [19]	Falta de un modelo para anticipar un infarto.	• <i>Lógica difusa.</i>	41.9 % de regresión.	Generaron un modelo neuro-difuso para la predicción de infartos.
Atallah et al. [20].	Se carece de un modelo para la estratificación del riesgo de arritmias malignas y el riesgo de muerte súbita cardíaca en el padecimiento de tetralogía de Fallot	• <i>Random Forest.</i>	Sensibilidad del 88,4 % y especificidad del 68,1 %.	Se calculó un "factor de importancia" para cada predictor, creando una puntuación de riesgo y 4 categorías de riesgo.
Rodriguez et al. [21].	Falta de un modelo para la detección temprana de pacientes con alto riesgo de muerte súbita cardíaca (MSC)	• <i>Support vector machine (SVM).</i>	El modelo SVM IDCLR vs. IDCHR alcanzó una precisión del 98.9 % con un área bajo la curva (AUC) de 0.96. Mientras que los grupos IDC y CON obtuvieron una precisión y AUC del 93.6 % y 0.94 %, respectivamente.	Se ha implementado un novedoso enfoque para evaluar la estratificación del riesgo en pacientes con IDC, que se basa en nuevos índices de análisis de acoplamiento, así como en medidas no lineales de VFC y BPV.
Continúa en la siguiente página				

Tabla 2.1 Análisis comparativo de artículos de investigación.

Artículo	Problema	Técnica de IA	Resultados	Aportación tecnológica
Lyon et al. [22].	Detectar variaciones fenotípicas en la Miocardiopatía Hipertrofica (MCH) a través del análisis computacional del ECG y describir las disparidades en los factores de riesgo clínicos, así como las diferencias anatómicas mediante el uso de imágenes de resonancia magnética cardíaca (RMC)	• <i>k-means</i>.	Los pacientes del Grupo 1A, con un QRS normal y onda T invertida, exhibieron puntajes de Riesgo-HCM-SCD elevados (1A: 4.0 %, 1B: 1.8 %, 2: 2.1 %, 3: 2.5 %, $p = 0.0001$) y una predominancia de hipertrofia septal y apical coexistente ($p < 0.0001$).	Con la adición de biomarcadores de onda T a la morfología de QRS en el análisis de agrupación, se identificaron cuatro grupos de MCH
Okada et al. [23].	Falta de un modelo de ML para predecir arritmias ventriculares en pacientes con miocardiopatía isquémica	• <i>Random forest</i>. • <i>Logistic regression</i>. • <i>Gradient boosted trees</i>. • <i>SVM</i>. • <i>Naive Bayes</i>. • <i>Nearest neighbors</i>.	El mejor modelo de ML clasificó con una precisión general del 91.7 %	Los clasificadores fueron entrenados utilizando 13 variables que incluyen edad, sexo, clase funcional de la NYHA, fracción de eyección del ventrículo izquierdo y relación corazón-mediastino.
Continúa en la siguiente página				

Tabla 2.1 Análisis comparativo de artículos de investigación.

Artículo	Problema	Técnica de IA	Resultados	Aportación tecnológica
Nakajima et al. [24].	Ausencia de un modelo de aprendizaje automático que permita predecir de manera distintiva el riesgo de eventos arrítmicos potencialmente fatales (ArE) y fallecimiento por insuficiencia cardíaca (HFD)."	• <i>Support vector machine</i>.	El algoritmo de ML clasificó con una precisión general del 81 % y clasificó correctamente el 86 % de los que no tenían VA	El análisis del SSC en las imágenes de LGE-CMR puede ser beneficioso para mejorar la evaluación del riesgo de arritmias ventriculares.
Sotto et al. [25].	Se carece de una selección de características correctas del conjunto de datos para la correcta clasificación de arritmias.	• <i>Random Forest</i>. • <i>Algoritmos genéticos</i>.	Precisión del modelo del 86.38 % para clasificación binaria y 77.69 para clasificación multiclase.	El método redujo el conjunto de datos de 279 a 26 atributos.
Oliver et al. [27].	Probar y evaluar un modelo de regresión logística para una predicción precisa del riesgo de muerte súbita cardíaca	• <i>Regresión logística</i>	Especificidad del 95 %	Se probó un algoritmo práctico que combina los datos recopilados para la atención de rutina en un modelo de riesgo fácil de usar aplicado en la prevención primaria de la MSC.
Continúa en la siguiente página				

Tabla 2.1 Análisis comparativo de artículos de investigación.

Artículo	Problema	Técnica de IA	Resultados	Aportación tecnológica
Fujita et al. [28].	Probar y validar una metodología para clasificar automáticamente las señales de Variabilidad del ritmo cardíaco de los sujetos normales y en riesgo de MSC mediante el uso de técnicas no lineales	• <i>KNN</i> • <i>Decision Tree</i> • <i>Support Vector Machine</i>	Lograron una precisión del 97,3 %, 89,4 %, 89,4 % y 94,7 % para la predicción de SCD uno, dos, tres y cuatro minutos antes del inicio de SCD, utilizando el clasificador SVM	Lograron predecir la MSC con 4 minutos de anticipación usando características no lineales como Renyi Entropy (REnt), Fuzzy Entropy(FE), los parámetros de Hjorth, la entropía de Tsallis (TEnt) y características energéticas de los coeficientes de la transformada de Wavelet discreta.
Kumari et al. [29].	Clasificar la arritmia con resultados más precisos en menos tiempo computacional.	• <i>Support Vector Machine</i> • <i>Transformada de wavelet</i>	La precisión del modelo es del 95,92 %.	La metodología completa se dividió en dos partes, primero utiliza el algoritmo de aprendizaje automático y el otro algoritmo de aprendizaje profundo.
Continúa en la siguiente página				

Tabla 2.1 Análisis comparativo de artículos de investigación.

Artículo	Problema	Técnica de IA	Resultados	Aportación tecnológica
Pereira et al. [30].	Combinación de 3 conjuntos de datos para la predicción de MSC.	• <i>Probabilistic neural network</i> • <i>Classification And Regression Tree</i>	La precisión del modelo es del 95 %.	Se ha demostrado que al combinar las variables de arritmia del ECG y las variables clínicas mejora el resultado en la predicción de los ataques cardíacos en comparación con los dos parámetros que se realizan individualmente.
Devi et al. [31].	Falsa detección de picos QRS en las señales de ECG	• <i>KNN</i>	No especificado	Se demostró la predicción de MSC utilizando el análisis de variabilidad de la frecuencia cardíaca
Vargas-Lopez et al. [33].	Aumentar el tiempo de detección de MSC	• <i>Multilayer Perceptron</i>	Precisión del 94 % 25 minutos antes de la MSC.	Se ha demostrado que la metodología propuesta es capaz de detectar un episodio de MSC 25 minutos antes de que aparezca con una precisión del 94 %.
Continúa en la siguiente página				

Tabla 2.1 Análisis comparativo de artículos de investigación.

Artículo	Problema	Técnica de IA	Resultados	Aportación tecnológica
Martinez-Alanis et al. [34].	Predecir la muerte súbita cardíaca mediante grabaciones de corto plazo (1000 latidos del corazón)	• <i>Support Vector Machine</i>	Intervalo de confianza del 95	El trabajo demostró que la combinación de índices de Variabilidad de Frecuencia Cardíaca y de huellas cardíacas cuentan con un valor predictivo alto para la taquiarritmia inminente en pacientes que llevaban un DAI (Desfibrilador Automático Implantable). Estos hallazgos basados en grabaciones a corto plazo son útiles para prevenir la MSC
Ebrahimzadeh et al. [35].	Mejorar el tiempo de predicción de MSC	• <i>Multilayer perceptron</i>	Precisión del 88.29 %.	Analizar el número de características resultó ser útil cuando se intenta mejorar el tiempo de predicción, así como el uso de la mezcla de clasificadores
Bhattacharya et al. [36].	Precisión baja en la clasificación de MSC	• <i>Logistic regression</i> • <i>Naive Bayes</i>	Sensibilidad = 0.73, especificidad = 0.76, c-index = 0.83	El modelo demostró la identificación de pacientes con arritmias ventriculares en función de su historial clínico

Después de llevar a cabo un análisis comparativo, se observa que el desarrollo de un módulo de predicción de muerte súbita cardíaca en niños mediante técnicas de inteligencia artificial propuesto en este estudio, toma en cuenta los aspectos evaluados y resumidos en la tabla 2.2.

2.3. Propuesta de solución

Tabla 2.2 Propuesta de solución.

Tecnología Web	Lenguaje	IDE	SGBD	Marco de trabajo	Metodología
Angular	Python	PyCharm	MySQL	Django REST Framework	UWE

Después de hacer un análisis de las tecnologías de información existentes en el mercado y comparar diferentes alternativas de solución considerando las tecnologías de Java y Python se determinó utilizar la propuesta que se observa en la tabla 2.2 en la cual se utiliza el *framework* Angular para el desarrollo de la interfaz gráfica, MySql como gestor de base de datos, la técnica de lógica difusa para el modelado de la predicción de muerte súbita cardíaca en niños, Django REST *Framework* para el desarrollo de los servicios REST y el IDE de desarrollo PyCharm.

Capítulo 3

Aplicación de la metodología

En este capítulo se presenta la aplicación de la metodología para el desarrollo de la aplicación.

Introducción

La presente solución propone el desarrollar un módulo de software que sea capaz de predecir el riesgo de muerte súbita cardíaca en niños mediante la técnica de lógica difusa. La aplicación propuesta utilizará un modelo basado en lógica difusa. La arquitectura de la aplicación se observa en la figura 3.2 y la metodología que se emplea en modelo de lógica difusa consta de cinco etapas las cuales son:

Primera etapa: esta consiste en la elección correcta de las variables de entrada y salida de los modelos difusos con apoyo de un médico especialista.

Segunda etapa: se procede a la *fuzificación* de los modelos a desarrollar, en otros términos se procede a la construcción de las funciones de pertenencia o membresía para cada modelo a diseñar.

Tercera etapa: en esta etapa se generan las reglas difusas en *python* y se validan con el apoyo del médico especialista.

Cuarta etapa: se realiza la evaluación pertinente y de acuerdo a los resultados, en esta etapa se validan las pruebas realizadas.

Quinta etapa: en esta última etapa se realiza un análisis minucioso de los gráficos de superficie de respuesta obtenido en cada modelo.

La metodología empleada en el desarrollo del modelo de lógica difusa para la predicción de riesgo de muerte súbita cardíaca en niños se muestra en la figura 3.1




Figura 3.1 Metodología del modelo de predicción de MSC en niños.

3.1. Arquitectura de la aplicación

En la figura 3.2 se presenta el esquema de la arquitectura de la aplicación web, como se muestra está basada en una metodología en capas donde se estructura el sistema en múltiples capas, y cada una de estas capas cumple un conjunto de tareas específicas. Estas capas están interconectadas a través de interfaces cuidadosamente definidas, lo que facilita la comunicación y la cooperación entre ellas.

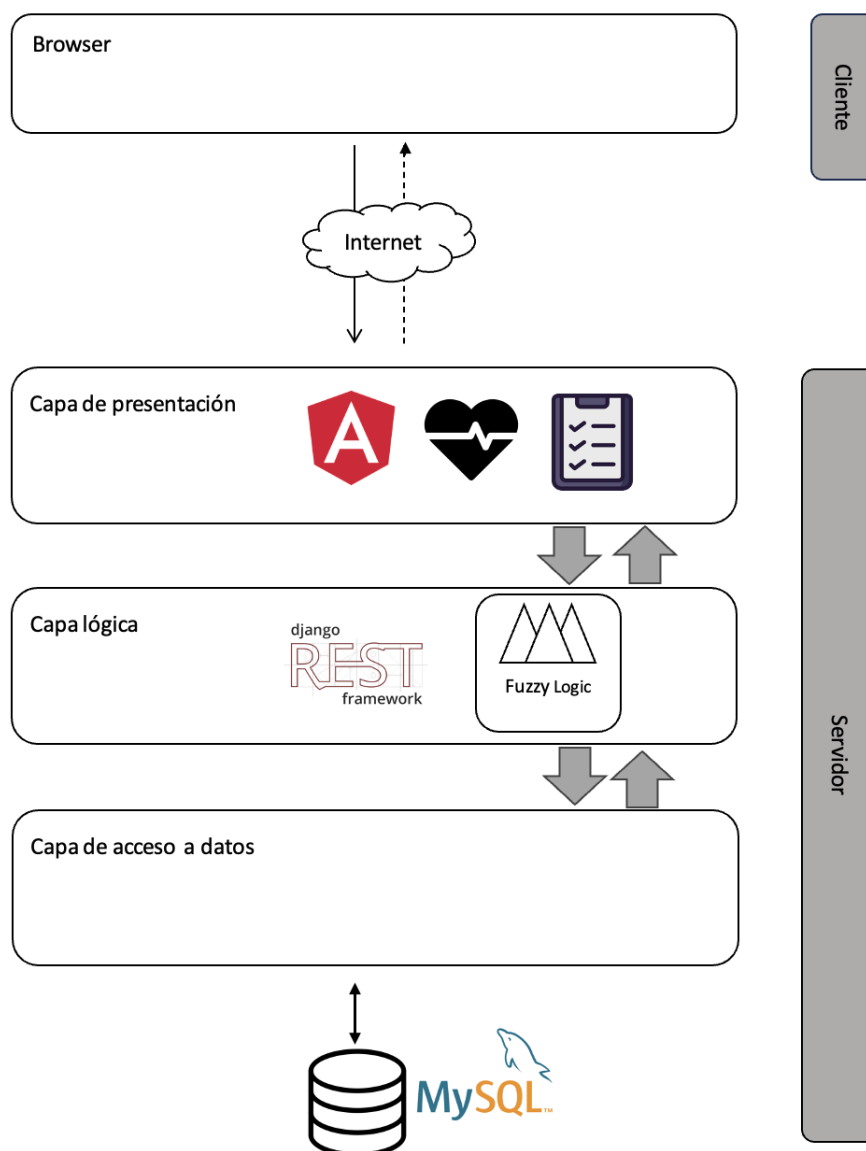


Figura 3.2 Arquitectura de la aplicación.

Los componentes que integran la arquitectura del sistema se describen a continuación:

Capa de Presentación: la función principal de esta capa radica en la presentación de información y como apoyo en la introducción de datos para los médicos y usuarios del sistema. La elección del *framework* Angular se justificó por su versatilidad y su facilidad de desarrollo. La interfaz proporcionará al sistema los datos de electrocardiogramas así como la información carácter médico, de manera que los módulos lleven a cabo la predicción de riesgo de muerte súbita cardíaca en niños.

Capa lógica: dentro de la estructura arquitectónica actual, la capa lógica se destaca como un componente más importante, dado que constituye el núcleo fundamental del sistema. En cuanto al lenguaje de programación, se utiliza *Python*, el cual tiene de un amplio reconocimiento y uso, particularmente en los campos de la ciencia de datos e inteligencia artificial. *Python* será empleado en colaboración con el *framework Django REST Framework*, cuya función principal consiste en el desarrollo de servicios *REST*.

Una vez que los datos se ingresan en la capa de presentación, se someten a un procesamiento a través de un modelo de lógica difusa que sirve para la predicción de riesgo de muerte súbita cardíaca en los niños, este modelo será previamente entrenado y validado. Tras la realización de esta predicción, los resultados obtenidos se almacenan en la base de datos correspondiente. La información así generada se pone a disposición del médico como un recurso de apoyo crucial en el proceso de toma de decisiones clínicas.

Capa de acceso a datos: la capa de acceso a datos proporciona las interfaces esenciales para facilitar la interacción entre los componentes externos al sistema, tales como la base de datos destinada al almacenamiento de información relacionada con diagnósticos médicos, datos de pacientes y datos de predicción.

3.1.1. Modelo de casos de uso UWE

En la Figura 3.3, se observa el funcionamiento del sistema a través de un diagrama de casos de uso. En la imagen, identificamos dos roles principales: el médico y el administrador del sistema. En total, se identificaron diecinueve casos de uso. Cinco de estos se centran en la gestión de usuarios, que incluye listar usuarios, buscar usuario, cambiar la contraseña del doctor, eliminar doctor y añadir doctor. Luego, tres casos de uso relacionados con la autenticación de usuarios, que abarcan el ingreso al sistema, la recuperación de contraseña y el cierre de sesión. Cuatro casos de uso se refieren a la gestión de pacientes, que engloba listar pacientes, añadir pacientes, editar pacientes y buscar pacientes. Por último, tenemos siete casos de uso destinados al expediente clínico del paciente, que incluyen ver expediente, predecir riesgo de MSC en niños, gestionar datos de medicamentos, gestionar datos de *holter*, gestionar síntomas, gestionar datos genéticos y gestionar datos de electrocardiogramas.




Figura 3.3 Diagrama de casos de uso

3.1.2. Diagrama de clases

En la figura 3.4 se muestran las clases que integran el sistema de predicción de muerte súbita cardíaca en niños y se describen a continuación:

Expediente: es el registro central de un paciente y contiene información personal, antecedentes médicos, diagnósticos, predicción de riesgo y tratamientos. Cada paciente tiene un único expediente.

Síntomas: esta clase comprende información acerca de los síntomas reportados por el paciente en edad pediátrica. Cada paciente tiene la posibilidad de tener múltiples registros de síntomas asociados a un expediente médico.

Electrocardiograma: representa los datos obtenidos por un electrocardiograma, que se utiliza para evaluar la actividad eléctrica del corazón. Los registros de electrocardiogramas están relacionado con el expediente clínico.

Medicamentos: incluye información sobre los medicamentos prescritos a los pacientes como parte de su tratamiento. Estos medicamentos están vinculados a expedientes médicos y diagnósticos específicos.

Holter: esta clase representa la información sobre la variabilidad de frecuencia cardíaca registrado por un dispositivo *holter* durante un período de tiempo.

Estudio Genético: la clase representa la información sobre los resultados de estudios genéticos realizados en los pacientes. Estos estudios proporcionan información relevante para el diagnóstico y tratamiento de condiciones cardíacas hereditarias.

Tratamiento Quirúrgico: en esta clase se representa la información sobre procedimientos quirúrgicos realizados en pacientes. Estos procedimientos están relacionados con expedientes médicos.

Imagen de Electrocardiograma: esta clase almacena representaciones visuales de los electrocardiogramas. Estas imágenes tienen un vínculo establecido a registros de electrocardiogramas y expedientes médicos.

Usuarios: la clase usuario gestiona los datos utilizados para el acceso al sistema.

Usuario con Rol de Doctor: representa a los médicos con acceso al sistema. Estos usuarios tienen permisos para acceder y gestionar expedientes médicos, realizar diagnósticos y acceder a las predicciones de riesgo de muerte súbita cardíaca.

Usuario con rol de administrador: representa a los usuarios con permisos de administración en el sistema. Estos usuarios tienen autoridad para gestionar usuarios y la configuración global del sistema.

Predicción: esta clase es la más relevante del sistema ya que mediante ella se gestionará la predicción de riesgo de MSC en los niños.




Figura 3.4 Diagrama de clases

3.1.3. Modelo de proceso UWE

En la figura 3.5 se presenta el diagrama del proceso de predicción, detallado a continuación:

1. El usuario completa previamente un formulario con los siguientes datos:

- Frecuencia cardíaca.
- Intervalo R-R.
- Intervalo QT.
- Edad.
- Presencia del patrón de Brugada.
- Evidencia de arritmia ventricular o fibrilación. ventricular
- Ausencia de pulso.
- Reanimación cardíaca.
- Taquicardia o arritmia.
- Historial familiar de muerte súbita.
- Historial familiar de alguna enfermedad asociada a MSC.
- Diagnóstico de MSC.
- Enfermedad genética patogénica.
- Evento de MSC.

2. El usuario hace clic en el botón de enviar.

3. Los datos se envían a dos modelos de predicción:

- Modelo para datos de ECG.
- Modelo para datos clínicos.

4. Los resultados de los modelos se validan.

5. En caso de detectarse algún error, el sistema informará al usuario sobre el error específico.

6. Si los datos son correctos, se procederá al cálculo del intervalo QT corregido utilizando la fórmula de Bazett [37].
 7. El sistema seleccionará el primer modelo de predicción por ECG de acuerdo a la edad enviada desde el formulario.
 8. El sistema enviará al modelo de predicción por datos clínicos el resultado del modelo de ECG y lo complementará con los datos enviados desde el formulario para la predicción final.
 9. El sistema presentará el resultado al usuario.
-




Figura 3.5 Modelo de proceso

3.1.4. Modelo de navegación UWE

En la figura 3.6 se presenta el modelo de navegación de la aplicación web. El menú principal ofrece las siguientes opciones de navegación:

1. Ir a inicio.
2. Buscar paciente.
3. Listar pacientes.
4. Ir a la sección de ayuda.
5. Salir.

El menú de la sección pacientes ofrece las siguientes opciones de navegación:

1. Agregar nuevo paciente.
2. Eliminar paciente.
3. Editar paciente.
4. Ir al expediente del paciente.

El menú de expediente ofrece las siguientes opciones de navegación:

1. Agregar datos de ECG.
 2. Eliminar datos de ECG.
 3. Editar datos de ECG.
 4. Agregar síntomas.
 5. Eliminar síntomas.
 6. Editar síntomas.
 7. Agregar medicamentos.
 8. Eliminar medicamentos.
 9. Editar medicamentos.
-

10. Agregar datos genéticos.
 11. Eliminar datos genéticos.
 12. Editar datos genéticos.
 13. Agregar datos de Holter.
 14. Eliminar datos de Holter.
 15. Editar datos de Holter.
 16. Generar predicción de MSC en niños.
 17. Eliminar la predicción de MSC en niños.
 18. Agregar datos de tratamiento quirúrgico.
 19. Editar datos de tratamiento quirúrgico.
 20. Eliminar datos de tratamiento quirúrgico.
-




Figura 3.6 Modelo de navegación

3.1.5. Modelo de presentación UWE

A continuación se muestran los diagramas establecidos para la presentación de la aplicación web.

Inicio de sesión

En la figura 3.7 se aprecia una estructura definida para el inicio de sesión del usuario, donde tiene la opción de ingresar al sistema a través de su correo electrónico y contraseña. Estos datos se verificarán por el sistema y, en caso de ser inexactos, se mostrará una ventana con un mensaje acorde al error. Si el usuario no logra acceder al sistema, tendrá la alternativa de restablecer la contraseña en la parte inferior izquierda.




Figura 3.7 Modelo de presentación de inicio de sesión

Sección principal

Como se aprecia en la Figura 3.8, el *dashboard* o sección principal contiene un panel lateral en el cual se encuentra el menú principal. En este panel se encuentran las siguientes opciones: buscar paciente por nombre, ir al inicio, acceder a la sección de pacientes, acceder a la sección de ayuda y, por último, salir o cerrar sesión. El resultado de la búsqueda se muestra en una ventana adicional, la cual contendrá el resultado. Además, la sección de perfil de usuario incluye información detallada sobre el usuario.




Figura 3.8 Modelo de presentación de sección principal

Sección pacientes

En la figura 3.9, se muestra la estructura de la sección de pacientes, donde se presenta la lista de los pacientes ordenados cronológicamente. Dentro de este listado, el usuario tiene la opción de agregar, eliminar o modificar la información de cada paciente. Asimismo, se incluye un formulario para dar de alta y modificar a los pacientes




Figura 3.9 Modelo de presentación de sección pacientes

Sección expediente

En la figura 3.10, se observa detalladamente la distribución de la estructura de la sección de expediente. En esta sección, se presenta información crucial sobre el estado del paciente.

En primer lugar, se proporciona información general que incluye el nombre del paciente, el diagnóstico actual, su edad, sexo, peso, talla y estado de salud. Estos datos generales permiten a los profesionales de la salud tener una visión rápida y completa del paciente.

Por otro lado, se encuentran datos específicos relacionados con la predicción de riesgo de muerte súbita cardíaca en niños (MSC), electrocardiogramas, datos genéticos, síntomas, registros Holter, medicamentos y tratamientos quirúrgicos. Estos elementos son cruciales para evaluar y gestionar la salud cardíaca del paciente de manera integral.

Para mejorar la usabilidad y accesibilidad de esta información, se presenta un sistema de pestañas. Cada categoría de información se presenta en pestañas separadas, lo que facilita la navegación y el acceso a los datos relevantes. Los usuarios tienen la posibilidad de moverse entre pestañas de manera sencilla, lo que agiliza el proceso de obtener la

información necesaria para la toma de decisiones médicas informadas y la planificación de tratamientos.




Figura 3.10 Modelo de presentación de la sección expediente

3.2. Descripción general del modelo de lógica difusa

La lógica difusa permite la toma de decisiones basada en términos subjetivos expresados a través de variables lingüísticas. Estas variables se valoran, modelan, *fusifican*, analizan mediante un mecanismo de inferencia y finalmente se *defusifican*.

En el marco de este proyecto, se presenta el modelo general en la figura 3.11, el cual consta de dos modelos de lógica difusa. El primer modelo se enfoca en la recepción de variables relacionadas con electrocardiogramas, mientras que el segundo utiliza una serie de preguntas como complemento para diagnosticar posibles casos de MSC en niños. Dado que el objetivo principal del primer modelo es predecir el riesgo de MSC en la población pediátrica, es necesario replicar este modelo en los rangos especificados en la figura 3.12, utilizando los universos del discurso adecuados para cada grupo de edad, que abarca desde los 12 meses hasta los 18 años [38], [39]. Esto conlleva a la creación de un total de nueve modelos de lógica difusa.




Figura 3.11 Modelo en cascada de lógica difusa para el riesgo de MSC

Edad	Frecuencia Cardíaca (Percentiles)						
	1	10	25	50	75	90	99
12-18 meses	88	103	112	123	132	140	156
18-24 meses	82	98	106	116	126	135	149
2-3 años	76	92	100	110	119	128	142
3-4 años	70	86	94	104	113	123	136
4-6 años	65	81	89	98	108	117	131
6-8 años	59	74	82	91	101	111	123
8-12 años	52	67	75	84	93	103	115
12-15 años	47	62	69	78	87	96	108
15-18 años	43	58	65	73	83	92	104

Figura 3.12 Relación de frecuencias cardíacas medidas en percentiles representado por rango de edades

3.2.1. Entorno de trabajo

El entorno se refiere a la configuración completa del ambiente de trabajo, incluyendo todo el software, los lenguajes de programación y los módulos utilizados para diseñar el modelo predictivo. En el presente proyecto, dicho modelo se basa en lógica difusa. Además, el entorno debe satisfacer dos aspectos importantes: la portabilidad y la distribución del código fuente del modelo predictivo.

3.2.2. Jupiter Notebooks

El Proyecto *Jupyter* es una iniciativa sin fines de lucro y de código abierto, derivada del Proyecto *IPython* en 2014, que ha evolucionado para apoyar la ciencia de datos interactiva y la computación científica en diversos lenguajes de programación. *Jupyter* se mantiene como un software completamente de código abierto, gratuito para todos, y se distribuye bajo los términos permisivos de la licencia BSD modificada.

En la Figura 3.13, se muestra la interfaz de *Jupyter Notebook*, donde se aprecia la funcionalidad de insertar hipervínculos, imágenes y vídeos. El código en *Python* se ejecuta por celdas.




Figura 3.13 Jupyter Notebook

3.2.3. Configuración

Para la configuración de *Python* se utilizó la distribución de *anaconda*, ya que es *open source*, y especialmente utilizado para ciencia de datos. para su descarga es necesario descargar el instalador en la pagina web (<https://www.anaconda.com/download>). Además,

Anaconda viene con Anaconda Navigator, una interfaz gráfica que simplifica la gestión de entornos y paquetes, y permite iniciar aplicaciones como Jupyter Notebook, Spyder y RStudio. Esto permite a los usuarios concentrarse en el desarrollo y análisis de datos sin tener que preocuparse por la configuración del entorno de trabajo.

Anaconda tiene un instalador gráfico de componentes mostrado en la figura 3.14 el cual permite instalar de forma simple las bibliotecas requeridas para el proyecto, a continuación se describen las bibliotecas utilizadas para el diseño del modelo de lógica difusa:

- **skfuzzy 0.2**: Permite el diseño de modelos predictivos de lógica difusa.
- **pandas 2.2.2**: Se utiliza principalmente para la manipulación de datos en formato tabular.
- **matplotlib**: Permite la creación de gráficos en 2D y 3D.
- **numpy**: Se utiliza para manipular matrices multidimensionales y realizar funciones matemáticas especializadas.
- **plotly**: Biblioteca para la creación de gráficos interactivos y visualizaciones de datos en 2D y 3D.




Figura 3.14 Anaconda Navigator

3.2.4. Definición de variables lingüísticas

A continuación, se describen las variables lingüísticas de entrada y salida empleadas en los modelos de predicción basados en datos de electrocardiogramas y datos clínicos.

Es relevante destacar que la selección de estas variables se llevó a cabo con el respaldo y asesoramiento de una destacada especialista en cardiología pediátrica, con amplios conocimientos en el ámbito de la muerte súbita cardíaca en niños.

Variables lingüísticas: modelo por datos de electrocardiogramas

Las variables asociadas al modelo de predicción por electrocardiogramas se muestran en la tabla 3.1, las variables de entrada incluyen la frecuencia cardíaca, el intervalo QT corregido, la presencia de un patrón de Brugada y la evidencia de fibrilación ventricular o arritmias ventriculares. La variable de salida se relaciona con el riesgo de muerte súbita cardíaca. Asimismo, se detallan los conjuntos difusos asociados a cada variable, junto con sus respectivos valores.

Tabla 3.1 Descripción de variables lingüísticas

Variable Lingüística	Descripción	Conjuntos Difusos	Valores
Frecuencia cardíaca	Número de veces que se contrae el corazón durante un minuto.	Bradicardia Normal Taquicardia	<103 lpm 112 - 132 lpm >140 lpm
QT corregido	Intervalo indicador utilizado para el diagnóstico de taquiarritmia ventricular maligna que implica riesgo de muerte súbita	Corto Normal Largo	<330 ms 370 - 440 ms >460 ms
Presencia de patrón de Brugada	Patrón electrocardiográfico encontrado en las derivaciones precordiales derechas que aumenta la predisposición a padecer arritmias ventriculares y MSC	Sí No	1 0
Evidencia de FV (Fibrilación Ventricular) o AV (Arritmia Ventricular)	FV es un ritmo cardíaco anormal que es potencialmente mortal y AV es un trastorno del ritmo cardíaco causado por señales eléctricas anormales en las cámaras inferiores del corazón	Sí No	1 0
Riesgo de MSC	Riesgo de experimentar un evento de MSC (Muerte Súbita Cardíaca) en la infancia	Bajo Medio Alto	>40 45 - 65 >70

Variable: frecuencia cardíaca

La frecuencia cardíaca es un indicador esencial que mide la cantidad de latidos por minuto en el corazón de una persona, destacando su importancia, especialmente en el caso de niños. Este parámetro proporciona valiosa información sobre la actividad eléctrica del corazón y su funcionamiento. Al analizar la frecuencia cardíaca, es posible identificar irregularidades, determinar si el corazón está trabajando correctamente o si presenta alguna afección. En el caso de las enfermedades asociadas a la muerte súbita cardíaca, existen síntomas que se reflejan en la frecuencia cardíaca, como la taquicardia o la bradicardia [40].

Esta variable se aborda en tres casos distintos, y para cada uno de ellos se define un conjunto difuso, que son los siguientes:

- **La frecuencia se sitúa en el rango de bradicardia.** Esto señala que la frecuencia cardíaca es lenta y el corazón no está bombeando suficiente sangre oxigenada al cuerpo.
- **La frecuencia se encuentra dentro del intervalo normal.** Esto indica que la frecuencia cardíaca se encuentra en valores óptimos.
- **La frecuencia se ubica en el rango de taquicardia.** Esto sugiere que la frecuencia cardíaca supera los valores normales y corazón se encuentra funcionando con anormalidad.

La variable frecuencia cardíaca tiene asignados tres conjuntos difusos, donde se utiliza la función de membresía trapezoidal. y son representados en la tabla 3.2

Tabla 3.2 Parámetros de frecuencia cardíaca en niños de 12 a 18 meses.

Variable lingüística	Parámetros			
	a	b	c	d
Bradicardia	88	103	112	
Normal	103	112	132	140
Taquicardia	132	140	156	

A continuación, se muestran los conjuntos difusos de esta variable, los cuales están representados mediante las ecuaciones 3.1, 3.2 y 3.3




Figura 3.15 Conjuntos difusos para frecuencia cardíaca

$$\mu_{\text{Bradicardia}}(x) = \begin{cases} 1 & \text{si } 88 \leq x \leq 103 \\ 1 - \frac{112 - x}{112 - 103} & \text{si } 103 < x \leq 112 \\ 0 & \text{si } x > 112 \end{cases} \quad (3.1)$$

$$\mu_{\text{Normal}}(x) = \begin{cases} 0 & \text{si } x \leq 103 \text{ o } x > 140 \\ 1 - \frac{x - 103}{112 - 103} & \text{si } 103 < x \leq 112 \\ 1 & \text{si } 112 < x \leq 132 \\ 1 - \frac{140 - x}{140 - 132} & \text{si } 132 < x \leq 140 \end{cases} \quad (3.2)$$

$$\mu_{\text{Taquicardia}}(x) = \begin{cases} 0 & \text{si } x \leq 132 \\ 1 - \frac{x - 132}{140 - 132} & \text{si } 132 < x \leq 140 \\ 1 & \text{si } 140 < x \leq 156 \\ 0 & \text{si } x > 156 \end{cases} \quad (3.3)$$

Tabla 3.3 Parámetros de QT corregido en niños menores de 15 años.

Variable lingüística	Parámetros			
	a	b	c	d
Corto	200	330	370	
Normal	330	370	440	460
Largo	440	460	600	

Variable: QT corregido

Esta variable se describe a través de tres conjuntos difusos, representados mediante una función de naturaleza trapezoidal. Su relevancia radica en su valor predictivo para el diagnóstico de taquiarritmias ventriculares malignas, las cuales están asociadas a síndromes que son propensos a desencadenar muerte súbita cardíaca [41], tales como el síndrome de QT largo [42] y el síndrome de QT corto.

Los conjuntos difusos que comprenden esta variable son los siguientes:

- **QT corregido en el rango corto:** Este indicador señala una mayor susceptibilidad del paciente a las arritmias ventriculares y a la muerte súbita cardíaca.
- **QT corregido dentro del rango normal:** Esto indica que el paciente se encuentra dentro de los valores normales para el intervalo QT.
- **QT corregido en el rango largo:** Esto sugiere que el paciente es propenso a presentar un QT prolongado, lo que es un indicativo de actividad cardíaca anormal y está asociado a síndromes como el Síndrome del QT Largo, que conlleva un alto riesgo de muerte súbita cardíaca.

La distribución de esta variable se detalla en la tabla 3.3 y son representadas en las ecuaciones 3.4, 3.5 y 3.6




Figura 3.16 Conjuntos Difusos para QTc

$$\mu_{\text{Corto}}(x) = \begin{cases} 1 & \text{si } 200 \leq x \leq 330 \\ 1 - \frac{370-x}{370-330} & \text{si } 330 < x \leq 370 \\ 0 & \text{si } x > 370 \end{cases} \quad (3.4)$$

$$\mu_{\text{Normal}}(x) = \begin{cases} 0 & \text{si } x \leq 330 \text{ o } x > 460 \\ 1 & \text{si } 370 \leq x \leq 440 \\ 1 - \frac{x-370}{440-370} & \text{si } 440 < x \leq 460 \end{cases} \quad (3.5)$$

$$\mu_{\text{Largo}}(x) = \begin{cases} 0 & \text{si } x \leq 440 \\ 1 - \frac{x-440}{460-440} & \text{si } 440 < x \leq 460 \\ 1 & \text{si } 460 \leq x \leq 600 \\ 0 & \text{si } x > 600 \end{cases} \quad (3.6)$$

Variable: presencia de patrón de Brugada

Esta variable desempeña un papel fundamental en el modelo de lógica difusa propuesto en este trabajo, ya que se trata de un patrón electrocardiográfico característico en

las derivaciones precordiales derechas. Su importancia radica en la predisposición que sugiere hacia las arritmias ventriculares y el síndrome de brugada que es una enfermedad asociada a la muerte súbita cardíaca [43]. Este patrón se convierte en un marcador esencial para evaluar el riesgo cardíaco.

Esta variable está representada en tres conjuntos difusos en una función trapezoidal cada uno y se describen a continuación:

- **Patrón de Brugada encontrado en el Electrocardiograma:** este hallazgo denota la presencia de los tres tipos del patrón de Brugada en el electrocardiograma, lo que constituye un sólido indicio de la presencia de la enfermedad de Brugada asociada a MSC.
- **Patrón de Brugada no encontrado en el electrocardiograma:** indica la ausencia de los tres tipos del patrón de Brugada en el registro cardíaco, lo que sugiere que no se han detectado signos de la enfermedad de Brugada en el electrocardiograma

La distribución de los conjuntos difusos esta variable se representada en la figura 3.17 y las ecuaciones 3.7 y 3.8




Figura 3.17 Variable Binaria: Presencia de Patrón de Brugada

$$\mu_{\text{Patrón de brugada Si}}(x) = \begin{cases} 1 & \text{si } x = 1 \\ 0 & \text{si } x \neq 1 \end{cases} \quad (3.7)$$

$$\mu_{\text{Patrón de brugada No}}(x) = \begin{cases} 1 & \text{si } x = 0 \\ 0 & \text{si } x \neq 0 \end{cases} \quad (3.8)$$

Variable: evidencia de arritmia o fibrilación ventricular

Esta variable desempeña un papel crucial en el modelo de predicción, dado que está relacionada con la arritmia ventricular, una de las afecciones clave en la muerte súbita cardiaca [44].

La distribución de los conjuntos difusos esta variable se representada en la figura 3.18 y las ecuaciones 3.9 y 3.10.




Figura 3.18 Variable Binaria: Presencia de Fibrilación Ventricular o Arritmia Ventricular

$$\mu_{\text{Fibrilación ventricular Si}}(x) = \begin{cases} 1 & \text{si } x = 1 \\ 0 & \text{si } x \neq 1 \end{cases} \quad (3.9)$$

$$\mu_{\text{Fibrilación ventricular No}}(x) = \begin{cases} 1 & \text{si } x = 0 \\ 0 & \text{si } x \neq 0 \end{cases} \quad (3.10)$$




Figura 3.19 Conjuntos Difusos para Riesgo de MSC

Variable de salida: riesgo de MSC por ECG

Esta variable tiene tres conjuntos difusos trapezoidales y representa el grado de riesgo de padecer muerte súbita cardíaca en edad pediátrica.

La distribución de los conjuntos difusos esta variable se representada en la figura 3.4 y la ecuación 3.11, 3.12 y 3.13

Tabla 3.4 Riesgo de muerte subida cardíaca en edad pediátrica.

Variable lingüística	Parámetros			
	a	b	c	d
Bajo	0	0	40	45
Medio	40	45	65	70
Alto	65	70	100	100

$$\mu_{\text{Bajo}}(x) = \begin{cases} 1 & \text{si } 0 \leq x \leq 40 \\ 1 - \frac{x-40}{45-40} & \text{si } 40 < x \leq 45 \\ 0 & \text{si } 65 \leq x \leq 100 \end{cases} \quad (3.11)$$

$$\mu_{\text{Medio}}(x) = \begin{cases} 0 & \text{si } 0 \leq x \leq 40 \\ 1 - \frac{45-x}{45-40} & \text{si } 40 < x \leq 45 \\ 1 & \text{si } 45 < x \leq 65 \\ 1 - \frac{x-65}{70-65} & \text{si } 65 < x \leq 70 \\ 0 & \text{si } 70 \leq x \leq 100 \end{cases} \quad (3.12)$$

$$\mu_{\text{Alto}}(x) = \begin{cases} 0 & \text{si } 0 \leq x \leq 65 \\ 1 - \frac{70-x}{70-65} & \text{si } 65 < x \leq 70 \\ 1 & \text{si } 70 < x \leq 100 \end{cases} \quad (3.13)$$

Variables: modelo por datos clínicos

En la tabla 3.5, se presentan las variables asociadas al modelo de predicción basado en datos clínicos. Las variables de entrada aportan información adicional a los electrocardiogramas, como antecedentes genéticos, historial de enfermedades familiares, afecciones previas y eventos relacionados con la muerte súbita.

Variable de entrada: riesgo de MSC por ECG

Esta variable es el resultado del primer modelo de predicción y se visualiza en la figura 3.4 y la ecuación 3.11, 3.12 y 3.13

Variables binarias

Las variables lingüísticas (síncope, ausencia de pulso, reanimación o desfibrilación, taquicardia, historia familiar de MSC, historia familiar de enfermedades asociadas a MSC, diagnóstico de enfermedad asociada a MSC, mutación genética patógena y evento de muerte súbita en el pasado) son binarias es decir solo admiten valores de 0 y 1 para representar estas variables. Estas funciones se visualizan en la Figura 3.20. y el modelo matemático se representa con las ecuaciones 3.14 y 3.15.

$$\mu_{\text{Si}}(x) = \begin{cases} 1 & \text{si } x = 1 \\ 0 & \text{si } x \neq 1 \end{cases} \quad (3.14)$$

$$\mu_{\text{No}}(x) = \begin{cases} 1 & \text{si } x = 0 \\ 0 & \text{si } x \neq 0 \end{cases} \quad (3.15)$$

Tabla 3.5 Descripción de Variables Lingüísticas

Variable Lingüística	Descripción	Conjuntos difusos	Valores
Riesgo de MSC por ECG	Detección de señales o patrones en un electrocardiograma (ECG) que indican un mayor riesgo de experimentar Muerte Súbita Cardíaca	Bajo	>40
		Medio	45 - 65
		Alto	>70
Síncope	El síncope es un término médico que se refiere a una pérdida temporal y repentina de la conciencia debido a una disminución transitoria del flujo sanguíneo al cerebro	Sí	1
		No	0
Ausencia de pulso	Falta de palpación o detección del latido cardíaco en una arteria, indicando la falta de circulación sanguínea	Sí	1
		No	0
Reanimación o desfibrilación	Procedimiento en el que se aplica una descarga eléctrica controlada al corazón para restablecer un ritmo cardíaco normal en caso de arritmias potencialmente mortales	Sí	1
		No	0
Taquicardia o Arritmia	Anormalidad en el ritmo cardíaco, lo que puede incluir taquicardia, bradicardia u otros patrones irregulares.	Sí	1
		No	0
Historia Familiar de MSC	Presencia de casos de fallecimientos repentinos y no esperados en familiares cercanos	Sí	1
		No	0

Tabla 3.5 – Continuación de la página anterior

Variable Lingüística	Descripción	Conjuntos difusos	Valores
Historia Familiar de enfermedades asociadas a MSC	Existencia de antecedentes médicos en la familia de condiciones cardíacas que aumentan el riesgo de muerte súbita, como arritmias o trastornos del corazón	Sí	1
		No	0
Diagnostico de enfermedad asociada a MSC	Identificación médica de afecciones o trastornos cardíacos que pueden desencadenar un episodio de muerte súbita	Sí	1
		No	0
Mutación genética patogénica	Alteración anormal en un gen que se ha vinculado con un mayor riesgo de sufrir eventos de muerte súbita relacionados con problemas cardíacos	Sí	1
		No	0
Evento de MSC en el pasado	Experiencia de sufrir un episodio de muerte súbita en el pasado	Sí	1
		No	0
Diagnostico de Riesgo de MSC	Evaluación médica que busca determinar la probabilidad de sufrir una MSC, a través de análisis de factores de riesgo	Poco probable	>40
		Probable	45 - 65
		Definitivo	>70




Figura 3.20 Funciones de membresía para la variable con valores 1 y 0

Variable de salida diagnostico de riesgo de MSC

Esta variable de salida tiene tres conjuntos difusos los cuales son: poco probable, probable y definitivo. Están representados con funciones trapezoidales y los conjuntos difusos se detallan en la figura 3.21 y se representa en las ecuaciones 3.16, 3.17 y 3.18




Figura 3.21 Conjuntos Difusos para Diagnóstico

$$\mu_{\text{Poco probable}}(x) = \begin{cases} 1 & \text{si } 0 \leq x \leq 40 \\ 1 - \frac{100-x}{60} & \text{si } 40 \leq x \leq 45 \\ 0 & \text{si } 45 \leq x \leq 100 \end{cases} \quad (3.16)$$

$$\mu_{\text{Probable}}(x) = \begin{cases} 0 & \text{si } 0 \leq x \leq 40 \\ 1 - \frac{x-40}{5} & \text{si } 40 \leq x \leq 45 \\ 1 & \text{si } 45 \leq x \leq 65 \\ 1 - \frac{70-x}{5} & \text{si } 65 \leq x \leq 70 \\ 0 & \text{si } 70 \leq x \leq 100 \end{cases} \quad (3.17)$$

$$\mu_{\text{Definitivo}}(x) = \begin{cases} 0 & \text{si } 0 \leq x \leq 65 \\ \frac{x-65}{5} & \text{si } 65 \leq x \leq 70 \\ 1 & \text{si } 70 \leq x \leq 100 \end{cases} \quad (3.18)$$

3.2.5. Análisis de inferencia

El modelo de inferencia empleado en esta investigación referente a la predicción del riesgo de muerte súbita cardíaca en niños se basa en las reglas de inferencia. Estas reglas operan de acuerdo con la estructura SI... CAUSA 1 (datos de electrocardiogramas) y CAUSA 2 (datos médicos)... ENTONCES... RIESGO DE MUERTE SÚBITA CARDÍACA, donde los factores representan las variables de entrada relacionadas con los datos de electrocardiogramas y datos médicos, y el riesgo de muerte súbita cardíaca es la variable de salida. El modelo de predicción de riesgo de muerte súbita cardíaca está configurado con un conjunto específico de reglas de inferencia, las cuales se derivan de las variables lingüísticas y los conjuntos que caracterizan a cada variable. A continuación, se detalla el número de reglas de inferencia para el modelo de predicción de riesgo de muerte súbita cardíaca.

Para determinar el total de número posible de combinaciones se debe multiplicar el número de conjuntos difusos por cada variable.

En el modelo de lógica difusa basado en ECG las variable frecuencia cardíaca tiene (3) conjuntos difusos, QTc (3), Patron de brugada (2) y Arritmia Ventricular (2).

$$n = 3 * 3 * 2 * 2$$

$$n = 36$$

En el código 3.1, se muestra un extracto de la codificación de las reglas de inferencia del modelo difuso, el cual consta de 36 reglas y está implementado utilizando la biblioteca skfuzzy.

```

1 # Regla 4: Si AV es 'si', Brugada es 'si', QTc del niño es 'normal' y
   frecuencia cardíaca es 'normal', entonces el riesgo de MSC es 'alto'.
2 rule4 = ctrl.Rule(av['si'] & brugada['si'] & qtchild['normal'] & frecar['
   normal'], msc['alto'])
3
4 # Regla 30: Si AV es 'no', Brugada es 'no', QTc del niño es 'normal' y
   frecuencia cardíaca es 'bradicardia', entonces el riesgo de MSC es '
   medio'.
5 rule30 = ctrl.Rule(av['no'] & brugada['no'] & qtchild['normal'] & frecar['
   bradicardia'], msc['medio'])
6
7 # Regla 31: Si AV es 'no', Brugada es 'no', QTc del niño es 'normal' y
   frecuencia cardíaca es 'normal', entonces el riesgo de MSC es 'bajo'.
8 rule31 = ctrl.Rule(av['no'] & brugada['no'] & qtchild['normal'] & frecar['
   normal'], msc['bajo'])
9
10 # Regla 32: Si AV es 'no', Brugada es 'no', QTc del niño es 'normal' y
    frecuencia cardíaca es 'taquicardia', entonces el riesgo de MSC es '
    medio'.
11 rule32 = ctrl.Rule(av['no'] & brugada['no'] & qtchild['normal'] & frecar['
    taquicardia'], msc['medio'])
12
13 # Regla 33: Si AV es 'no', Brugada es 'no', QTc del niño es 'largo' y
    frecuencia cardíaca es 'bradicardia', entonces el riesgo de MSC es 'alto
    '.
14 rule33 = ctrl.Rule(av['no'] & brugada['no'] & qtchild['largo'] & frecar['
    bradicardia'], msc['alto'])

```

Código 3.1 Extracto de reglas del modelo difuso

En el modelo de datos clínicos y ecg la variable riesgo de MSC por ECG tiene (3) conjuntos difusos, síncope (2), ausencia de pulso (2), reanimación o desfibrilación (2), taquicardia o arritmia (2), historia familiar de MSC (2), historia familiar de enfermedades asociadas a MSC (2), diagnóstico de enfermedades asociadas a MSC (2), mutación genética patógena (2) y evento de MSC en el pasado (2).

Para el modelo de lógica difusa de ECG, se necesitan 36 reglas de inferencia, mientras que para el modelo complementario de datos clínicos se requieren 3581 reglas. En la tabla 3.6, se presenta el conjunto de reglas utilizado para el modelo de predicción de riesgo de muerte súbita cardíaca por variables de electrocardiograma.

Tabla 3.6 Tabla de reglas de inferencia del modelo de predicción por ECG

AV o FV	Patrón Brugada	QTc	FC	Riesgo
sí	sí	corto	bradicardia	alto
sí	sí	corto	normal	alto
sí	sí	corto	taquicardia	alto
sí	sí	normal	bradicardia	alto
sí	sí	normal	normal	alto
sí	sí	normal	taquicardia	alto
sí	sí	largo	bradicardia	alto
sí	sí	largo	normal	alto
sí	sí	largo	taquicardia	alto
sí	no	corto	bradicardia	alto
sí	no	corto	normal	alto
sí	no	corto	taquicardia	alto
sí	no	normal	bradicardia	alto
sí	no	normal	normal	alto
sí	no	normal	taquicardia	alto
sí	no	largo	bradicardia	alto
sí	no	largo	normal	alto
sí	no	largo	taquicardia	alto
no	sí	corto	bradicardia	alto
no	sí	corto	normal	alto
no	sí	corto	taquicardia	alto
no	sí	normal	bradicardia	alto
no	sí	normal	normal	alto
no	sí	normal	taquicardia	alto
no	sí	largo	bradicardia	alto
Continúa en la siguiente página				

AV o FV	Patrón Brugada	QTc	FC	Riesgo
no	sí	largo	normal	alto
no	sí	largo	taquicardia	alto
no	no	corto	bradicardia	alto
no	no	corto	normal	alto
no	no	corto	taquicardia	alto
no	no	normal	bradicardia	medio
no	no	normal	normal	bajo
no	no	normal	taquicardia	medio
no	no	largo	bradicardia	alto
no	no	largo	normal	alto
no	no	largo	taquicardia	alto

Tabla 3.7 Extracto de reglas de inferencia del modelo de lógica difusa de datos clínicos

R ₁	S ₂	A ₃	R ₄	A ₅	H ₆	E ₇	D ₈	A ₉	E ₁₀	M ₁₁	H ₁₂	D ₁₃
bajo	si	si	si	si	si	si	si	si	si	si	si	probable
bajo	si	si	si	si	si	si	si	si	si	si	no	probable
bajo	si	si	si	si	si	si	si	si	si	no	si	probable
bajo	si	si	si	si	si	si	si	si	si	no	no	probable
bajo	si	si	si	si	si	si	si	si	no	si	si	probable
bajo	si	si	si	si	si	si	si	si	no	si	no	probable
bajo	si	si	si	si	si	si	si	si	no	no	si	probable
bajo	si	si	si	si	si	si	si	no	si	si	si	probable
bajo	no	si	si	si	si	si	si	si	si	si	si	poco probable
bajo	no	si	si	si	si	si	si	si	si	si	no	poco probable
bajo	no	si	si	si	si	si	si	si	si	no	si	poco probable
bajo	no	si	si	si	si	si	si	si	si	no	no	poco probable
bajo	no	si	si	si	si	si	si	si	no	si	si	poco probable
bajo	no	si	si	si	si	si	si	si	no	si	no	poco probable
bajo	no	si	si	si	si	si	si	si	no	no	si	poco probable

Continúa en la siguiente página

R ₁	S ₂	A ₃	R ₄	A ₅	H ₆	E ₇	D ₈	A ₉	E ₁₀	M ₁₁	H ₁₂	D ₁₃
bajo	no	si	si	si	si	si	si	si	no	no	no	poco probable
bajo	no	si	si	si	si	si	si	no	si	si	si	poco probable
alto	si	si	no	no	si	si	si	no	no	no	no	definitivo
alto	si	si	no	no	si	si	no	si	si	si	si	definitivo
alto	si	si	no	no	si	si	no	si	si	si	no	definitivo
alto	si	si	no	no	si	si	no	si	si	no	si	definitivo
alto	si	si	no	no	si	si	no	si	si	no	no	definitivo
alto	si	si	no	no	si	si	no	si	no	si	si	definitivo
alto	si	si	no	no	si	si	no	si	no	si	no	definitivo
alto	si	si	no	no	si	si	no	si	no	si	no	definitivo
alto	si	si	no	no	si	si	no	si	no	no	si	definitivo

R₁: Riesgo por ECG, S₂: Síncope, A₃: Ausencia de pulso, R₄: Reanimación, A₅: Arritmia, H₆: Historia de MSC, E₇: Historia de Enfermedades asociadas a MSC, D₈: Diagnóstico de Enf MSC, A₉: Síncope por actividad física, E₁₀: Síncope por evento de sobresalto, M₁₁: Mutación genética patogénica, H₁₂: historial MSC previo, D₁₃: Diagnostico.

3.2.6. Análisis de superficie de respuesta

En el diseño y análisis de modelos predictivos, la superficie de respuesta es una herramienta crucial para la optimización y análisis de procesos. Se utiliza para validar las relaciones entre las variables de entrada y las variables de respuesta o salida.

En las figuras 3.22 a 3.30 se observa el comportamiento del riesgo de muerte súbita cardíaca (MSC) en niños con respecto a los valores de QTc y frecuencia cardíaca. Los gráficos tridimensionales muestran que dicho comportamiento varía según la edad, y que la frecuencia cardíaca se ajusta a rangos de valores específicos en las distintas etapas de desarrollo del niño.

En la figura 3.22 se presenta el gráfico de superficie de respuesta para el sistema de predicción del riesgo de muerte súbita cardíaca, basado en lógica difusa. Este gráfico tridimensional ilustra cómo la interacción entre las variables de entrada, frecuencia cardíaca y QTc, afecta el riesgo de MSC, que es la variable de salida.

Comportamiento del Riesgo de MSC

1. Relación entre frecuencia cardíaca y riesgo de MSC

- Cuando la frecuencia cardíaca se encuentra por encima o por debajo de los valores estables para el niño, según su edad, el riesgo de muerte súbita cardíaca tiende a aumentar.

2. Por el contrario, cuando la frecuencia cardíaca se aproxima a los valores estables para el niño, según su edad, el riesgo de muerte súbita cardíaca tiende a disminuir.

3. Relación entre QTc y riesgo de MSC

- Cuando el valor del QTc se encuentra por encima o por debajo de los valores normales para el niño, según su edad, el riesgo de muerte súbita cardíaca tiende a aumentar.
- En cambio, cuando el valor del QTc se aproxima a los valores normales, el riesgo tiende a disminuir.

4. Interacción entre QTc y frecuencia cardíaca

- Se observa en la región del gráfico donde tanto la frecuencia cardíaca como el valor de QTc son altos, que el riesgo de MSC es elevado. Este comportamiento sugiere que el corazón está en estado de taquicardia con una repolarización ventricular aumentada, lo que indica un mayor riesgo de arritmias peligrosas.
 - Por otro lado, también se aprecia en la región del gráfico donde la frecuencia cardíaca y el valor de QTc son bajos, que el riesgo de MSC es alto. Este comportamiento sugiere que el corazón está en estado de bradicardia con una repolarización ventricular reducida. Esta condición está fuertemente asociada con padecimientos como el síndrome de QT corto, una condición genética rara que predispone a la muerte súbita cardíaca.
-




Figura 3.22 Relación del riesgo de MSC en función del QTC y la fc en niños de 12 a 18 meses.




Figura 3.23 Relación del riesgo de MSC en función del QTC y la fc en niños de 18 meses a 2 años




Figura 3.24 Relación del riesgo de MSC en función del QTC y la fc en niños de 2 a 3 años




Figura 3.25 Relación del riesgo de MSC en función del QTC y la fc en niños de 3 a 4 años




Figura 3.26 Relación del riesgo de MSC en función del QTC y la fc en niños de 4 a 6 años




Figura 3.27 Relación del riesgo de MSC en función del QTC y la fc en niños de 6 a 8 años




Figura 3.28 Relación del riesgo de MSC en función del QTc y la fc en niños de 8 a 12 años




Figura 3.29 Relación del riesgo de MSC en función del QTc y la fc en niños de 12 a 15 años




Figura 3.30 Relación del riesgo de MSC en función del QTc y la fc en niños de 15 a 18 años

3.2.7. Configuración de los modelos de predicción de lógica difusa en Python

En fragmento de código 3.2 se presenta la implementación de un modelo difuso para evaluar el riesgo de muerte súbita cardíaca en un niño de 12 a 18 meses. Este modelo se basa en la teoría de conjuntos difusos y utiliza la biblioteca *scikit-fuzzy* de *Python* para su desarrollo.

Primero, se importan las bibliotecas necesarias, incluyendo *numpy* para operaciones numéricas y *skfuzzy* para la lógica difusa. Se definen los antecedentes del sistema difuso, que incluyen la frecuencia cardíaca en niños de 15 a 18 años (*frecar*), los valores del intervalo QT corregido (*qtchild*), el patrón de Brugada (*brugada*), y la presencia de arritmia ventricular (*av*).

Para cada antecedente se establecen las funciones de pertenencia que representan las categorías relevantes. Por ejemplo, la frecuencia cardiaca se divide en las categorías de bradicardia, normal y taquicardia, cada una con su respectiva función de pertenencia trapezoidal. De manera similar, se definen las categorías para el intervalo QT corregido, el patrón de Brugada, y la arritmia ventricular.

El consecuente del sistema difuso es el riesgo de muerte súbita cardiaca (msc), el cual se divide en las categorías de riesgo bajo, medio y alto. Las reglas difusas se establecen de acuerdo a combinaciones específicas de los antecedentes, donde se define el nivel de riesgo asociado a cada combinación.

```
1 # Importar bibliotecas necesarias
2 import numpy as np
3 import skfuzzy as fuzz
4 import skfuzzy.control as ctrl
5
6 # Definir universo del discurso para variables de entrada
7 frecar = ctrl.Antecedent(np.arange(40, 150, 1), 'frecar') # Frecuencia
    cardiaca en niños de 15 a 18 años
8 qtchild = ctrl.Antecedent(np.arange(200, 600, 1), 'qtc') # Valores de QTc
    en frecuencia cardiaca
9 brugada = ctrl.Antecedent(np.arange(0, 1.1, 0.1), 'brugada') # Valores de
    patrón de Brugada
10 av = ctrl.Antecedent(np.arange(0, 1.1, 0.1), 'av') # Valores asociados a
    arritmia ventricular
11
12 # Definir funciones de pertenencia para las variables de entrada
13 frecar['bradicardia'] = fuzz.trapmf(frecar.universe, [40, 40, 58, 65]) #
    Frecuencia cardiaca asociada a bradicardia
14 frecar['normal'] = fuzz.trapmf(frecar.universe, [58, 65, 83, 92]) #
    Frecuencia cardiaca normal en niños
15 frecar['taquicardia'] = fuzz.trapmf(frecar.universe, [83, 92, 150, 150]) #
    Frecuencia cardiaca asociada a taquicardia
16
17 qtchild['corto'] = fuzz.trapmf(qtchild.universe, [200, 200, 330, 370]) #
    QT Corto
18 qtchild['normal'] = fuzz.trapmf(qtchild.universe, [330, 370, 450, 470]) #
    QT Normal
```

```

19 qtchild['largo'] = fuzz.trapmf(qtchild.universe, [450, 480, 600, 600]) #
    QT Largo
20
21 # Definir funciones automáticas de membresía para síndrome de Brugada y
    arritmia ventricular
22 brugada.automf(names=['no', 'si']) # Brugada
23 av.automf(names=['no', 'si']) # Arritmia ventricular
24
25 # Definir consecuente para el riesgo de muerte súbita cardiaca (MSC)
26 msc = ctrl.Consequent(np.arange(0, 101, 1), 'mscrisk') # Riesgo de MSC de
    0 a 100
27
28 msc.automf(names=['bajo', 'medio', 'alto']) # Riesgo alto, medio y bajo de
    MSC
29
30 # Definir reglas difusas
31 rule0 = ctrl.Rule(av['si'] & brugada['si'] & qtchild['corto'] & frecar['
    bradicardia'], msc['alto'])
32 rule1 = ctrl.Rule(av['si'] & brugada['si'] & qtchild['corto'] & frecar['
    normal'], msc['alto'])
33 # Agregar más reglas según sea necesario...
34
35 # Crear sistema de control y simulación
36 system = ctrl.ControlSystem([rule0, rule1]) # Lista de reglas difusas
37 simulacion = ctrl.ControlSystemSimulation(system)
38
39 # Establecer valores de entrada para la simulación
40 simulacion.input['frecar'] = 88
41 simulacion.input['qtc'] = 455
42 simulacion.input['brugada'] = 1
43 simulacion.input['av'] = 1
44
45 # Realizar la simulación y obtener resultado
46 simulacion.compute()
47 print(simulacion.output['mscrisk']) # Imprimir resultado del riesgo de MSC
48 msc.view(simulacion) # Visualizar la salida del sistema de control
49
50 # Guardar el modelo para uso futuro
51 import joblib

```

```
52 filename = 'modelos/model_15a.model' # Nombre y ubicación del archivo de
    modelo
53 joblib.dump(simulacion, filename) # Guardar el modelo
```

Código 3.2 Modelo difuso para riesgo de muerte súbita cardiaca en niños de 15 a 18 años

En la figura 3.31 se muestran los 9 modelos de lógica difusa para su implementación en el servicio *REST*.




Figura 3.31 Modelos de lógica difusa de acuerdo a la edad

Capítulo 4

Resultados

En este capítulo se presentan los resultados obtenidos al implementar un modelo secuencial de lógica difusa para la predicción de riesgo de muerte súbita en una población de niños con predisposición al SQT.

4.1. Planteamiento del Caso de Estudio

Se planteó el desarrollo de un módulo de software para la predicción del riesgo de muerte súbita cardíaca en la población infantil de México. Este módulo se implementó utilizando un entorno de servicios *REST* y una interfaz de usuario para el consumo de estos servicios, conocida como *API REST*. La aplicación correspondiente, comúnmente denominada *front-end*, permite a los usuarios interactuar de manera intuitiva y eficiente con el sistema de predicción.

4.2. Requerimientos del Negocio

El área de investigación en cardiopatías congénitas del Hospital Infantil de México Federico Gómez tiene el requerimiento de una aplicación que sirva como apoyo al diagnóstico de riesgo de MSC a través de un canal web. Dicha aplicación tiene como objetivo utilizar técnicas de inteligencia artificial que permitan segmentar el riesgo de muerte súbita a través de variables de entrada seleccionadas por un grupo de expertos en MSC.

4.3. Obtención de datos

La adquisición de datos constituye una de las etapas fundamentales en el diseño de un modelo predictivo, dado que la calidad de los datos obtenidos determina la técnica a emplear. En este proceso se abarca la creación de bases de datos, tanto relacionales como no relacionales, e implica la fase de captura de datos, que se utiliza cuando no existe un sistema previo de almacenamiento de datos establecido.

4.4. Determinación de datos necesarios

Para determinar la clasificación óptima de un algoritmo de clasificación por *machine learning* o lógica difusa, es esencial disponer de datos suficientes y de alta calidad para el análisis. En esta fase, se contó con el apoyo de un médico especialista en MSC, quien colaboró en establecer los límites de la población de niños a analizar. Esta población incluyó niños con predisposición a MSC, específicamente aquellos con el síndrome de QT Largo, un padecimiento altamente asociado a la MSC, y otra población de niños sanos para contrastar los resultados obtenidos.

4.5. Obtención de la base de datos

En los proyectos de clasificación o predicción, es crucial contar con un conjunto de datos equilibrado, aunque no siempre es posible lograrlo. En el caso particular de la MSC, la falta de una cultura de recolección de datos y una baja difusión de este padecimiento han dado lugar a una limitada disponibilidad de datos, lo que dificulta la implementación de un modelo de predicción basado en *machine learning*. Sin embargo, dentro de las técnicas de inteligencia artificial existen alternativas viables para desarrollar un modelo de predicción sin necesidad de contar con un gran volumen de datos. En este caso específico, se optó por la lógica difusa, la cual es efectiva cuando existe un sesgo significativo en el conjunto de datos.

El desarrollo de la base de datos (Bd) se realizó en el departamento de investigación de arritmias del Hospital Infantil de México Federico Gómez (HIMFG) uno de los hospitales de pediatría más importantes de México.

Para la construcción de la bd en este proyecto, se realizó la recolección manual de datos de pacientes con SQTL, centrándose especialmente en el historial del paciente y en datos de electrocardiogramas, incluyendo valores como la frecuencia cardíaca en reposo, el QT y el QT corregido. Además, se recopilieron datos de síntomas presentes en pacientes con SQTL, tales como síncope, antecedentes familiares de MSC y otros padecimientos asociados a MSC.

En este proyecto se contó con una cohorte de niños con SQTL que incluyó 56 niños diagnosticados con Síndrome de QT Largo y 13 niños sanos. Esta cohorte abarcó casos registrados desde 2014 hasta 2024 la población se observa de forma gráfica en la figura 4.2.




Figura 4.1 Diagnóstico de los niños

En la figura 4.2, se observa la distribución por edades. En el análisis de la frecuencia cardíaca, se asignaron los rangos aceptables basados tanto en la literatura como en la experiencia del especialista. Estos rangos se clasifican en tres tipos: bradicardia, rangos normales y taquicardia.

En la tabla 4.1 se presenta un fragmento de la base de datos obtenida por el HIMFG. Las primeras ocho columnas representan las variables de entrada para el modelo de predicción, basadas en los síntomas e historial del paciente. Las columnas Fc y QTc representan los valores de entrada para el modelo basado en datos de electrocardiogramas. Por último, la columna Categoría muestra el nivel de riesgo, el cual fue determinado por la Doctora especialista en MSC."




Figura 4.2 Distribución de niños con SQTL y niños sanos por rangos de edad

Tabla 4.1 Datos de clasificación por probabilidad

No.	Sexo	Edad	Ant fam de SCTL	Prevalencia de FV /TV	Ant fam de MSC	Arrit	TV	Sínc	Fc	QTc	Categoría
1	0	14	0	0	0	0	0	1	60	474	Probable
2	0	14	0	1	0	1	0	1	80	459	Probable
3	0	8	1	0	0	0	0	1	66	569	Probable
4	0	10	0	0	0	0	0	0	97	467	Probable
5	1	5	0	0	0	1	0	0	60	400	Probable
6	0	12	0	0	0	0	1	0	63	485	Probable
7	0	11	0	0	0	1	0	1	60	519	Probable
8	0	10	0	0	0	0	0	1	50	471	Probable
9	0	15	0	0	0	0	0	0	58	510	Probable
10	0	1	0	0	0	0	0	0	114	463	Probable
11	1	2	1	1	0	1	1	1	90	450	Definitivo
12	0	11	0	0	0	0	0	1	85	470	Definitivo
13	1	15	0	1	0	1	1	1	91	439	Definitivo
14	0	9	0	1	0	0	0	1	80	651	Definitivo
15	0	17	0	0	1	0	0	1	90	447	Definitivo
16	1	13	0	1	1	0	0	1	75	511	Definitivo
17	1	5	0	1	0	1	1	1	60	514	Definitivo
18	0	14	0	0	0	1	0	1	62	487	Definitivo
19	1	3	0	0	0	0	0	0	93	420	Poco probable
20	1	5	0	0	0	0	0	0	100	438	Poco probable
21	1	7	0	0	0	0	0	0	80	424	Poco probable
22	0	8	0	0	0	0	0	0	90	460	Poco probable
23	0	7	0	0	0	0	0	0	105	454	Poco probable
24	1	9	0	0	0	0	0	0	95	465	Poco probable
25	1	6	0	0	0	0	0	0	90	420	Poco probable
26	1	1	0	0	0	0	0	0	101	446	Poco probable
27	1	5	0	0	0	0	0	0	100	464	Poco probable

4.6. Matriz de confusión

La evaluación del modelo a través de la matriz de confusión, como se muestra en la tabla 4.2, 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 %, como se presenta en la tabla 4.3. 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'

Tabla 4.2 Matriz de confusión

Clase Real	Clase Predicha		
	Definitivo	Probable	Poco Probable
Definitivo	9	0	0
Probable	0	56	0
Poco Probable	0	4	9

Tabla 4.3 Resultado del modelo de predicción

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

4.7. Diseño de servicio REST en *Django Rest Framework*

En esta sección se presenta el diseño de la aplicación de predicción de riesgo de muerte súbita cardíaca en niños, acerca de cómo es que se realizan unas llamadas *REST* a la aplicación.

4.7.1. Modelo de predicción de lógica difusa por parámetros clínicos

El código 4.1 muestra el proceso completo implementado en *Django* para predecir el riesgo de muerte súbita cardíaca basado en parámetros clínicos. Esta implementación se realiza utilizando el *framework Django REST*, específicamente en la vista *API* (API View). El objetivo del modelo es evaluar diversos parámetros clínicos de los pacientes y

proporcionar una predicción precisa sobre el riesgo de sufrir un evento de muerte súbita cardíaca.

El proceso comienza con la recepción de los datos clínicos del paciente, los cuales se envían a través de una solicitud *POST* a la *API*. Estos datos incluyen información relevante como la frecuencia cardíaca, el intervalo QT corregido (QTc), entre otros parámetros médicos críticos. Una vez recibidos, los datos se validan para asegurar que cumplen con los requisitos necesarios para la predicción.

Posteriormente, los datos validados son procesados por el modelo de predicción. Este modelo se entrenó previamente utilizando lógica difusa lo que le permite analizar los patrones presentes en los datos y realizar una predicción informada sobre el riesgo de muerte súbita cardíaca.

El resultado de esta predicción se devuelve al solicitante en forma de una respuesta *JSON*, que incluye el nivel de riesgo (alto, medio o bajo) y los parámetros clínicos utilizados en la predicción.

```
1
2 # importación de bibliotecas necesarias
3 from rest_framework.views import APIView
4 from rest_framework.response import Response
5 from rest_framework import status
6 import joblib
7 from \textit{Django}.http import JsonResponse
8
9 #clase destinada a la predicción de riesgo de MSC
10
11 class PrediccionAPIViewSet (APIView):
12     def post(self, request):
13         # Validar datos
14         errores = validar_datos(request)
15         if errores:
16             return Response(status=status.HTTP_406_NOT_ACCEPTABLE, data=
17 errores)
18
19         # Cargar modelos basados en la edad
20         modelos = {
21             1: 'bib/model_12m.model',
22             2: 'bib/model_18m.model',
```

```
22         3: 'bib/model_2a.model',
23         4: 'bib/model_3a.model',
24         5: 'bib/model_4a.model',
25         6: 'bib/model_6a.model',
26         7: 'bib/model_8a.model',
27         8: 'bib/model_12a.model',
28         9: 'bib/model_15a.model'
29     }
30
31     edad = request.data.get('edad')
32     model_path = modelos.get(edad)
33     if not model_path:
34         return Response(status=status.HTTP_400_BAD_REQUEST, data={'
35 error': 'Edad no válida'})
36
37     model = joblib.load(model_path)
38
39     # Obtener otros parámetros
40     fc = request.data.get('fc')
41     qtc = request.data.get('qtc')
42     brugada = int(request.data.get('pbrugada', False))
43     av = int(request.data.get('avofv', False))
44     sincope = int(request.data.get('sincope', False))
45     aupulso = int(request.data.get('aupulso', False))
46     ejercicio = int(request.data.get('ejercicio', False))
47     sobresalto = int(request.data.get('sobresalto', False))
48     mutacion = int(request.data.get('mutacion', False))
49     historiamsc = int(request.data.get('historiamsc', False))
50     arritmia = int(request.data.get('arritmia', False))
51     reanimacion = int(request.data.get('reanimacion', False))
52     histofammsc = int(request.data.get('histofammsc', False))
53     histenfmsc = int(request.data.get('histenfmsc', False))
54     enfmsc = int(request.data.get('enfmsc', False))
55
56     # Asignar entradas al modelo
57     model.input['frecar'] = int(fc)
58     model.input['qtc'] = int(qtc)
59     model.input['brugada'] = brugada
60     model.input['av'] = av
```

```
60     model.compute()
61     prediccionEcg = model.output['mscrisk']
62
63     # Crear objeto predicción
64     p = pred()
65     p.setSincope(sincope)
66     p.setRiskEcg(int(prediccionEcg))
67     p.setAusenciaPulso(aupulso)
68     p.setReanimacion(reanimacion)
69     p.setArritmia(arritmia)
70     p.setHistoriaFamMsc(histofammsc)
71     p.setHistoriaEnf(historiamsc)
72     p.setDiagEnfAsoc(enfmesc)
73     p.setActividadFisica(ejercicio)
74     p.setEventoSobresalto(sobresalto)
75     p.setMGenetica(mutacion)
76     p.setHistorialPMsc(histenfmesc)
77
78     # Generar predicción
79     p.getPrediccion().compute()
80     diagnostico = p.getPrediccion().output['diagnostico']
81
82     # Generar respuesta JSON
83     data = {
84         'edad': edad, 'riskecg': prediccionEcg, 'fc': fc, 'qtc': qtc, '
85         brugada': brugada, 'av': av,
86         'sincope': sincope, 'aupulso': aupulso, 'ejercicio': ejercicio,
87         'sobresalto': sobresalto,
88         'mutacion': mutacion, 'historiamsc': historiamsc, 'reanimacion'
89         : reanimacion,
90         'histofammsc': histofammsc, 'histenfmesc': histenfmesc, 'enfms':
91         enfmesc, 'arritmia': arritmia,
92         'diagnostico': diagnostico
93     }
94
95     return JsonResponse(data, status=status.HTTP_200_OK)
```

Código 4.1 Modelo de predicción de riesgo de MSC por parámetros clínicos

El bloque de código 4.2 muestra la configuración de la ruta en *Django* que mapea la URL: **api/prediccion/** a una vista llamada **PrediccionApiViewSet**. La cual se encarga de enviar la predicción por el método *POST*.

```
1 from django.urls import path
2 from .views import PrediccionApiViewSet
3
4 urlpatterns = [
5     path('api/prediccion/', PrediccionApiViewSet.as_view()),
6 ]
```

Código 4.2 Configuración de rutas en *Django*

El fragmento de código 4.3 define un serializador utilizando *Django REST Framework*, que se emplea para convertir instancias de modelos *Django* a formatos de datos como *JSON*.

```
1 class PrediccionmScSerializer(serializers.ModelSerializer):
2     class Meta:
3         model = PrediccionmSc
4         fields = '__all__'
```

Código 4.3 Configuración de serializador

El siguiente código 4.4 presenta la configuración de la clase **PrediccionmSc**, la cual se utiliza en *Django* para mapear la base de datos con el modelo de datos correspondiente. Este modelo está diseñado para almacenar y gestionar las predicciones de riesgo de muerte súbita cardíaca (MSC) para pacientes.

```
1 from django.db import models
2
3 class PrediccionmSc(models.Model):
4     # Fecha de la predicción, se establece automáticamente al crear la
5     # instancia
6     fecha = models.DateField(auto_now_add=True, blank=True, null=True)
7
8     # Edad del paciente, puede ser nulo
9     edad = models.IntegerField(blank=True, null=True)
10
11     # Frecuencia cardíaca del paciente
12     fc = models.IntegerField()
13
14     # Intervalo QT corregido del paciente
```

```
12     qtc = models.IntegerField()
13     # Indicador de si hay síndrome de Brugada (True/False)
14     brugada = models.BooleanField(default=False)
15     # Indicador de anomalía ventricular (True/False)
16     av = models.BooleanField(default=False)
17     # Indicador de si ha habido síncope (True/False)
18     sincope = models.BooleanField(default=False)
19     # Indicador de si el ejercicio está implicado (True/False)
20     ejercicio = models.BooleanField(default=False)
21     # Indicador de si hay sobresalto (True/False)
22     sobresalto = models.BooleanField(default=False)
23     # Indicador de aumento de pulso (True/False)
24     aupulso = models.BooleanField(default=False)
25     # Indicador de si ha habido reanimación (True/False)
26     reanimacion = models.BooleanField(default=False)
27     # Indicador de si hay arritmia (True/False)
28     arritmia = models.BooleanField(default=False)
29     # Historial familiar de muerte súbita cardíaca (True/False)
30     histofammsc = models.BooleanField(default=False)
31     # Historial personal de muerte súbita cardíaca (True/False)
32     historiamsc = models.BooleanField(default=False)
33     # Historial de enfermedades relacionadas con muerte súbita cardíaca (
34     True/False)
35     histenfmsc = models.BooleanField(default=False)
36     # Indicador de enfermedades miocárdicas específicas (True/False)
37     enfms = models.BooleanField(default=False)
38     # Indicador de si hay una mutación genética relacionada (True/False)
39     mutacion = models.BooleanField(default=False)
40     # Valor de riesgo basado en el ECG (número decimal con precisión)
41     riskecg = models.DecimalField(max_digits=30, decimal_places=20)
42     # Diagnóstico basado en el modelo (número decimal con precisión)
43     diagnostico = models.DecimalField(max_digits=30, decimal_places=20)
44     # Relación con el modelo 'Expediente', borra la predicción si el
45     expediente es borrado
46     expediente = models.ForeignKey('Expediente', on_delete=models.CASCADE)
47
48     def __str__(self):
49         # Representación legible del objeto, retorna la frecuencia cardíaca
50         como cadena
```

48

```
return str(self.fc)
```

Código 4.4 Configuración de clase Prediccionmsc

4.7.2. Angular Cli

En el presente trabajo, se utilizó el marco de trabajo *Angular* para el diseño *Front-End* de la aplicación, debido a su notable modularidad en la programación, su capacidad de escalar eficientemente y su diseño responsivo, que facilita la adaptación a diferentes dispositivos y tamaños de pantalla de manera efectiva.

El código 4.5 presenta la función **getPrediccionEcgJson**, la cual se encarga de realizar una llamada a la *API REST* del *Back-End* de la aplicación mediante una solicitud *POST*. Esta función es parte del archivo **prediccion.service.ts**. Su propósito es enviar datos específicos al servidor y recibir una respuesta que contiene las predicciones generadas por el modelo.

```
1 public getPrediccionEcgJson(data: PrediccionData): Observable<
  PrediccionResponse> {
2   let url = this.apiUrl + 'api/prediccion';
3   return this.http.post<PrediccionResponse>(url, data).pipe(
4     catchError(error => {
5       console.error('Error en la solicitud:', error);
6       return throwError('Error en la solicitud');
7     })
8   );
9 }
```

Código 4.5 Llamada API REST al servicio predicción.

El fragmento de código 4.6 presenta la función **submitApplication** la cual se ejecuta al momento de dar clic al botón enviar, esta función inicia alternando el estado de validación, si la validación es exitosa, procede a actualizar los valores de QT corregido (QTC) y frecuencia cardíaca (FC) en el servicio **prediccion.service.ts**. Posteriormente, realiza una solicitud *HTTP POST* a la *API REST* para obtener una predicción basada en los datos del formulario. Una vez que se recibe la respuesta, se asigna el *ID* del expediente, se guarda la predicción en el servidor y se notifica la creación de una nueva

predicción y se genera una estructura *JSON* a partir de la respuesta, la cual es gestionada mediante un *observable*. Finalmente, el método cierra el *modal* actual y abre un nuevo *modal* que muestra los resultados obtenidos.

```
1 submitApplication() {
2   # Alternar la variable de validación
3   this.validate = !this.validate;
4   # Si la validación no está activada
5   if (!this.validate) {
6     # Verificar y asignar el valor de QTC si está definido y no es nulo
7     if (this.formPrediccion.value.qtc !== undefined && this.formPrediccion.
      value.qtc !== null) {
8       this.prediccionservice.qtc = this.formPrediccion.value.qtc;
9     }
10    # Verificar y asignar el valor de FC si está definido y no es nulo
11    if (this.formPrediccion.value.fc !== undefined && this.formPrediccion.
      value.fc !== null) {
12      this.prediccionservice.fc = this.formPrediccion.value.fc;
13    }
14    # Realizar la solicitud POST para obtener la predicción
15    this.prediccionservice.getPrediccionEcgJson(this.formPrediccion.value).
      subscribe(
16      (response: Predictions) => {
17        # Asignar el expediente al objeto de respuesta
18        response.expediente = this.expservice.idexpediente;
19        # Guardar la predicción en el servidor
20        this.prediccionservice.GuardarPrediccion(response).subscribe(
21          res => {
22            # Notificar que una nueva predicción ha sido creada
23            this.prediccionservice.notifyNewPredreated();
24          },
25          err => {
26            # Manejar error al guardar la predicción
27            console.log(err);
28          }
29        );
30        # Actualizar la edad en el servicio
31        this.prediccionservice.edad = response.edad;
32        # Agregar la predicción en el servicio
```

```
33     this.prediccionservice.setPrediccionEcgJson(response);
34     # Generar estructura JSON a partir del objeto de respuesta
35     const objetoJson = response;
36     const estructuraJson = generarEstructuraJson(objetoJson);
37     const estructuraObservable: Observable<any> = of(estructuraJson);
38     # Agregar la estructura JSON en el servicio
39     this.prediccionservice.setArbolJson(estructuraObservable);
40     # Suscribirse al observable de la estructura JSON
41     estructuraObservable.subscribe(
42         (data: any) => {
43             # Agregar la estructura JSON en el servicio
44             this.prediccionservice.setArbolJson(data);
45         }
46     );
47     # Cerrar el modal actual
48     this.modal.dismissAll();
49     # Abrir el componente de resultados en un modal
50     this.modal.open(ResultadoComponent, { size: 'lg' });
51 },
52 (error) => {
53     # Manejar error en la solicitud POST
54     console.error('Error al realizar la solicitud POST:', error);
55 }
56 );
57 }
58 }
```

Código 4.6 Llamada API REST al servicio predicción.

4.8. Uso de la aplicación

En el presente capítulo se muestran 2 casos de estudio con el objetivo de demostrar los resultados obtenidos con la aplicación. Esta aplicación está diseñada específicamente para la predicción del nivel de riesgo de muerte súbita cardíaca en los niños.

Para utilizar la aplicación, es necesario iniciar sesión en el sistema proporcionando los datos de usuario y contraseña, tal como se ilustra en la Figura 4.3. Posteriormente, desde la pantalla de bienvenida de la aplicación (Figura 4.4), los usuarios son enviados

un panel de información. En este *dashboard*, se presentan estadísticas detalladas de las predicciones realizadas.




Figura 4.3 Inicio de sesión




Figura 4.4 Dashboard

4.8.1. Caso de estudio: Predicción de riesgo de muerte súbita cardíaca en un paciente pediátrico con SQTL

Se seleccionó el expediente de un paciente masculino de 8 años con diagnóstico de SQTL que acudió al servicio de urgencias del hospital. El paciente presenta las siguientes características clínicas:

- Frecuencia Cardíaca (FC): 70 lpm
- Intervalo PR (PR): 200 ms
- Complejo QRS (QRS): 170 ms
- Intervalo QT (QT): 560 ms
- Intervalo QT corregido (QTc): 615 ms

Además de tener los siguiente síntomas: síncope previo y ha sufrido reanimación.

Estos parámetros son relevantes para evaluar el riesgo de muerte súbita cardíaca y se utilizan en el análisis y predicción de eventos cardiovasculares en pacientes pediátricos.

A continuación se describe la funcionalidad de la aplicación para este caso de estudio en particular. Como primer paso desde la pantalla de bienvenida de la aplicación (Figura 4.4), se selecciona la opción “Pacientes”. Posteriormente, se selecciona el expediente del paciente. Luego, se elige la opción “Predicciones”, como se muestra en la figura 4.5. En esta sección, se hace clic en "Generar una nueva predicción". Se capturan los valores de todas las variables requeridas del paciente en los campos correspondientes y se pulsa el botón “Enviar”, tal y como se muestra en la Figura 4.6. Acto seguido, el sistema consulta al modelo de muerte súbita cardíaca y predice si existe riesgo de que el paciente presente muerte súbita cardíaca. En esta sección se mostrarán dos valores de predicción: uno por ECG (Figura 4.7) y otro por parámetros clínicos e historial del paciente (Figura 4.8). El sistema indica un riesgo del 81.63 % por ECG y del 72.75 % de riesgo general.




Figura 4.5 Expediente

Predicción de riesgo

Edad: 8 a 12 años Fc (bpm): 70 Qtc (ms): 615

☐ Presencia de patrón de brugada
☒ Ha presentado Síncope
☐ Es portador de una mutación genética patogénica.
☐ Historia familiar de MSC
☐ Arritmia

☐ Ausencia de pulso
☐ Presentó un síncope cuando realizaba ejercicio o actividad física
☐ Existe historia personal de muerte súbita previa.
☐ Historia de enf asociada a MSC
☐ El paciente o un espectador percibieron taquicardia o arritmia

☐ Evidencia de arritmia FC o FV
☐ Presentó síncope inmediatamente después de un evento de estrés o sobresalto
☒ Ha sufrido reanimación cardiaca ó Desfibrilación Eléctrica.
☐ Diagnostico de enfermedad causante de MSC

Cerrar Enviar

Figura 4.6 Formulario de predicción de riesgo




Figura 4.7 Resultado de predicción parte 1



Figura 4.8 Resultado de predicción parte 2

4.8.2. Caso de estudio: Predicción de riesgo de muerte súbita cardíaca en un paciente sano

Como segundo caso, se seleccionó un paciente sano del sexo femenino con las siguientes características:

- Frecuencia Cardíaca (FC): 90 latidos por minuto (lpm)
- Intervalo PR (PR): 160 milisegundos (ms)
- Complejo QRS (QRS): 100 ms
- Intervalo QT (QT): 360 ms
- Intervalo QT corregido (QTc): 436 ms

Sin otros síntomas adicionales.

Estos parámetros representan un perfil de salud normal en una paciente femenina. Es importante tener en cuenta estos valores como referencia para comparar con pacientes que presenten condiciones médicas específicas.

Siguiendo los pasos previos del caso anterior, al hacer clic en 'Generar nueva predicción', se ingresan los valores de todas las variables necesarias del paciente en los campos correspondientes y se presiona el botón 'Enviar', como se ilustra en la Figura 4.9. A continuación, el sistema consulta al modelo de muerte súbita cardíaca y predice si existe riesgo de que el paciente sufra una muerte súbita cardíaca. En esta sección se presentan dos valores de predicción: uno por ECG (Figura 4.10) y otro por parámetros clínicos e historial del paciente (Figura 4.11), con una probabilidad de riesgo del 16.67 % por ECG y del 26.34 % en general.

Predicción de riesgo

Edad:

6 a 8 años

Fc (lpm):

93

Qtc (ms):

420

☐ Presencia de patrón de brugada

☐ Ausencia de pulso

☐ Evidencia de arritmia FC o FV

☐ Ha presentado Síncope

☐ Presentó un síncope cuando realizaba ejercicio o actividad física

☐ Presentó síncope inmediatamente después de un evento de estrés o sobresalto

☐ Es portador de una mutación genética patológica.

☐ Existe historia personal de muerte súbita previa.

☐ Ha sufrido reanimación cardiaca ó Desfibrilación Eléctrica.

☐ Historia familiar de MSC

☐ Historia de enf asociada a MSC

☐ Diagnostico de enfermedad causante de MSC

☐ Arritmia

☐ El paciente o un espectador percibieron taquicardia o arritmia

Cerrar

Enviar

Figura 4.9 predicción caso 2




Figura 4.10 Resultado de predicción parte 1




Figura 4.11 Resultado de predicción parte 2

4.8.3. Aportación al Estado de la Práctica

Tabla 4.4 Tabla de aportación al estado de la práctica.

Aspecto	Estado de la Práctica	Aportación del Trabajo Propuesto	Impacto Potencial	Referencia
Precisión en la Clasificación	Modelos de lógica difusa para la clasificación del riesgo de enfermedades cardíacas, tienen una precisión promedio del 58 % en conjuntos de datos complejos.	Incremento de la precisión al 97.7 % mediante el uso de una nueva arquitectura basada en un modelo secuencial de lógica difusa.	Mejora significativa en aplicaciones críticas como la predicción del riesgo de muerte súbita cardíaca.	I. Iancu et al. [16].
Manejo del Rango de Edades para Predicción de Riesgo	Los modelos de lógica difusa no tienen una segmentación del rango de edades.	Generación de modelos de predicción de riesgo acorde a la edad infantil.	Aumento en la eficiencia de la predicción de riesgo de acuerdo a la edad del paciente.	P. Kora et al. [17].
Modelos Secuenciales de Lógica Difusa	Los modelos actuales tienden a utilizar solo un modelo de lógica difusa.	La implementación de modelos secuenciales de lógica difusa permite mejorar la precisión de la predicción.	Aplicación más efectiva en escenarios del mundo real, donde la edad del paciente influye de manera significativa en la predicción de riesgo.	L. J. Muhammad et al. [18].
Facilidad de Implementación	Las herramientas actuales requieren un alto nivel de conocimiento en programación avanzada.	Desarrollo de una plataforma con una interfaz gráfica intuitiva que permite la implementación sin necesidad de codificación.	Facilidad de uso por parte de profesionales no técnicos en el área de la salud.	Atallah et al. [20].

Capítulo 5

Conclusiones

Con base en los resultados obtenidos y las conclusiones derivadas de este trabajo, el uso de la lógica difusa demuestra un gran potencial como herramienta de apoyo para clasificar el nivel de riesgo de Muerte Súbita Cardíaca en niños, particularmente en aquellos con predisposición genética al Síndrome de QT Largo (SQTL). Los resultados obtenidos en este estudio sugieren una precisión del 97.7 %, una sensibilidad del 89.74 %, una especificidad del 89.74 % y un puntaje F1 del 92.78 % en la clasificación de los niveles de riesgo, lo cual es prometedor y sugiere que la lógica difusa podría ser útil en este contexto.

Es importante destacar que este estudio tiene limitaciones y que los resultados deben interpretarse con cautela. Se identificó que la categoría de riesgo 'poco probable' presenta mayores desafíos en términos de clasificación correcta, lo cual indica áreas de mejora para futuras investigaciones.

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 los cuales 56 presentaban diagnóstico de SQTL y 13 correspondían a individuos sanos.

Uno de los principales retos identificados en este estudio fue la escasez de datos específicos de pacientes pediátricos con SQTL en México, limitación que refleja la falta de acceso a información amplia y detallada en este grupo poblacional. Esta ausencia de datos suficientes dificultó la implementación de técnicas de aprendizaje automático, que generalmente requieren grandes volúmenes de datos para entrenar modelos robustos y confiables. Ante esta limitación, se optó por un enfoque de lógica difusa debido a su ca-

pacidad de generar sistemas de inferencia basados en reglas y su menor dependencia de grandes conjuntos de datos, lo cual resultó ser una alternativa viable en el contexto actual.

A pesar de estas limitaciones, los resultados obtenidos en este estudio sugieren que la lógica difusa es una herramienta valiosa en la evaluación del riesgo de MSC en niños con SQTL, y plantean la necesidad de futuras investigaciones que amplíen y validen este enfoque en un contexto clínico más amplio y con una base de datos de mayor diversidad. En este sentido, la recopilación de más datos sobre casos pediátricos de SQTL en México sería fundamental para mejorar los modelos predictivos y abrir la posibilidad de emplear técnicas avanzadas de aprendizaje automático en futuras investigaciones.

5.0.1. Recomendaciones

Con base en las limitaciones identificadas y en los hallazgos de este estudio, se formulan las siguientes recomendaciones para futuras investigaciones en el campo de la evaluación del riesgo de Muerte Súbita Cardíaca (MSC) en la población infantil.

1. **Incorporar datos bajo condiciones de estrés:** Se recomienda ampliar la recopilación de datos para incluir mediciones obtenidas bajo condiciones de estrés, como pruebas de esfuerzo. Esto permitirá una evaluación más completa del riesgo cardíaco en niños y mejorar la capacidad predictiva de los modelos.
 2. **Explorar variables adicionales del ECG:** Es importante considerar variables más allá de los valores asociados al corazón en reposo, como el complejo QRS, el segmento ST y el intervalo PR. La inclusión de estas variables en futuros estudios enriquecerá la evaluación del riesgo de MSC y brindará una visión más completa de la salud cardíaca de los pacientes pediátricos.
 3. **Validar el modelo en cohortes más amplias:** Se sugiere realizar estudios con cohortes más grandes para validar y generalizar los resultados obtenidos en este estudio. Esto ayudará a confirmar la eficacia y la aplicabilidad del enfoque de la lógica difusa en la evaluación del riesgo de MSC en una población infantil más diversa.
 4. **Explorar técnicas de aprendizaje automático complementarias:** Además de la lógica difusa, se recomienda explorar técnicas de aprendizaje automático complementarias que mejoren la precisión y la sensibilidad en la clasificación del riesgo de
-

MSC en niños. La combinación de enfoques amplía la posibilidad de obtener resultados más robustos y confiables.

5. **Explorar el grupo de enfermedades de tipo estructural del corazón:** Se recomienda investigar el impacto de otras enfermedades de tipo estructural del corazón, como el síndrome de repolarización temprana y síndromes genéticos con afectación vascular, en la evaluación del riesgo de MSC en niños. La inclusión de estos factores incrementaría la precisión del modelo predictivo.
 6. **Considerar otros tipos de estudios clínicos:** Se sugiere incluir la realización de estudios clínicos adicionales, como holter de 24 horas y mesa inclinada, para evaluar de manera más completa la función cardíaca y la respuesta del sistema cardiovascular en la población infantil. Estos estudios aportarían información adicional sobre el riesgo de eventos cardíacos graves.
-

Apéndice A

Glosario de Términos Médicos

A.1. Introducción

Este apéndice proporciona definiciones y explicaciones de los términos médicos utilizados a lo largo de esta tesis.

A.2. Términos Médicos

A.2.1. Muerte Súbita Cardíaca (MSC)

- **Definición:** Muerte inesperada causada por una pérdida abrupta de la función cardíaca. Ocurre dentro de una hora del inicio de los síntomas en una persona sin una condición cardíaca previa conocida.

A.2.2. Intervalo QTc

- **Definición:** El intervalo QT corregido es una medida del tiempo que tarda el corazón en recargarse entre latidos, corregido para la frecuencia cardíaca.

A.2.3. Frecuencia Cardíaca

- **Definición:** Número de veces que el corazón late por minuto.

A.2.4. Arritmia

- **Definición:** Ritmo cardíaco irregular o anormal.

A.2.5. Cardiomiopatía

- **Definición:** Enfermedad del músculo cardíaco que dificulta la capacidad del corazón para bombear sangre al resto del cuerpo.

A.2.6. Electrocardiograma (ECG)

- **Definición:** Prueba que registra la actividad eléctrica del corazón.

A.2.7. Bradiarritmia

- **Definición:** Ritmo cardíaco anormalmente lento.

A.2.8. Taquiarritmia

- **Definición:** Ritmo cardíaco anormalmente rápido.

A.2.9. Hipertrofia Ventricular

- **Definición:** Engrosamiento de las paredes del ventrículo del corazón.

A.2.10. Fibrilación ventricular

- **Definición:** Las cámaras inferiores del corazón se contraen de forma rápida y caótica. Es la causa más frecuente de MSC.
-

Referencias

- [1] J. Avila-Tomás, M. Mayer-Pujadas, and V. Quesada-Varela, “La inteligencia artificial y sus aplicaciones en medicina i: introducción antecedentes a la ia y robótica,” *Atención Primaria*, vol. 52, pp. 778–784, 12 2020. [Online]. Available: <http://dx.doi.org/10.1016/j.aprim.2020.04.013>
- [2] C. Aracena, F. Villena, F. Arias, and J. Dunstan, “Aplicaciones de aprendizaje automático en salud,” *Revista Médica Clínica Las Condes*, vol. 33, pp. 568–575, 11 2022. [Online]. Available: <http://dx.doi.org/10.1016/j.rmcl.2022.10.001>
- [3] L. Zadeh, “Fuzzy logic,” *Computer*, vol. 21, pp. 83–93, 4 1988.
- [4] K. S. Cano-Hernández, S. Nava-Townsend, A. Sánchez-Boiso, R. Sánchez-Urbina, A. Contreras-Ramos, J. R. Erdmenger-Orellana, T. Tamayo-Espinosa, R. Becerra-Becerra, B. Segura-Stanford, L. Solano-Fiesco, and N. A. Balderrábano-Saucedo, “Prevalencia y espectro de las enfermedades que predisponen a la muerte súbita cardíaca en niños mexicanos: una muestra obtenida del hospital infantil de México federico gómez,” *Archivos de Cardiología de México*, vol. 88, pp. 268–276, 10 2018. [Online]. Available: <http://dx.doi.org/10.1016/j.acmx.2017.08.003>
- [5] J. G. González, J. J. C. Álvarez, L. M. Perdomo, and M. F. A. Lanza, “Uso del electrocardiograma en atención primaria: estudio elapi,” *Medicina General y de Familia*, vol. 5, pp. 172–173, 10 2016. [Online]. Available: <http://dx.doi.org/10.1016/j.mgyf.2016.02.005>
- [6] “What is an arrhythmia?” [Online]. Available: <https://www.nhlbi.nih.gov/health/arrhythmias>
- [7] J. A. LOZANO, “Arritmias cardíacas y su tratamiento,” *Offarm*, vol. 20, no. 11, pp. 96–105, 2001. [Online]. Available: <https://www.elsevier.es/es-revista-offarm-4-articulo-arritmias-cardiacas-su-tratamiento-13023366>
- [8] J. J. S. Mateo, M. S. Molina, and J. R. G. Blanes, “Miocardiopatía hipertrófica,” *Medicina Clínica*, vol. 150, pp. 434–442, 6 2018. [Online]. Available: <http://dx.doi.org/10.1016/j.medcli.2017.09.013>
- [9] E. G. Espallargas, S. G. Pelegrín, A. S. Liso, M. de la Cruz Ferrer, I. G. Romea, J. M. Duarte, and M. R. Jiménez, *Medicina integral : MEDICINA PREVENTIVA Y ASISTENCIA EN ATENCION PRIMARIA DE SALUD*. IDEPSA, 11 1980, vol. 38. [Online]. Available: <http://www.elsevier.es/es-revista-medicina-integral-63-articulo-taquiarritmias-13022431>
- [10] N. Balderrábano-Saucedo, . *Muerte súbita. Short Stories Studio*, 2021.

- [11] Celaya-Cota, "Muerte súbita cardíaca y RCP en México." <https://www.smcardiologia.org.mx/dia-mundial-del-corazon/muerte-subita-y-rcp-en-mexico/>, 2018, [Online; accessed 12-April-2023].
- [12] S. Aziz, S. Ahmed, and M.-S. Alouini, "Ecg-based machine-learning algorithms for heartbeat classification," *Scientific Reports*, vol. 11, p. 18738, 9 2021. [Online]. Available: <http://dx.doi.org/10.1038/s41598-021-97118-5>
- [13] D. M. Popescu, J. K. Shade, C. Lai, K. N. Aronis, D. Ouyang, M. V. Moorthy, N. R. Cook, D. C. Lee, A. Kadish, C. M. Albert, K. C. Wu, M. Maggioni, and N. A. Trayanova, "Arrhythmic sudden death survival prediction using deep learning analysis of scarring in the heart," *Nature Cardiovascular Research*, vol. 1, pp. 334–343, 4 2022. [Online]. Available: <http://dx.doi.org/10.1038/s44161-022-00041-9>
- [14] P. Mylavarapu, O. M. Aldaas, D. Darden, F. T. Han, K. S. Hoffmayer, D. E. Krummen, G. Ho, F. Raissi, G. K. Feld, and J. C. Hsu, "B-po05-006 using machine learning to identify patients likely to require repeat catheter ablation for atrial fibrillation: Insights from the uc san diego af ablation registry," *Heart Rhythm*, vol. 18, p. S373, 8 2021. [Online]. Available: <http://dx.doi.org/10.1016/j.hrthm.2021.06.926>
- [15] "Mexico - estadísticas vitales. defunciones generales y fetales 2015." [Online]. Available: https://www.inegi.org.mx/rnm/index.php/catalog/231/related_materials?idPro=
- [16] I. Iancu, "Heart disease diagnosis based on mediative fuzzy logic," *Artificial Intelligence in Medicine*, vol. 89, pp. 51–60, 7 2018. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0933365717301586>
- [17] P. Kora, K. Meenakshi, K. Swaraja, A. Rajani, and M. K. Islam, "Detection of cardiac arrhythmia using fuzzy logic," *Informatics in Medicine Unlocked*, vol. 17, p. 100257, 2019. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S2352914819301996>
- [18] L. J. Muhammad and E. A. Algehyne, "Fuzzy based expert system for diagnosis of coronary artery disease in nigeria," *Health and Technology*, vol. 11, pp. 319–329, 3 2021. [Online]. Available: <http://link.springer.com/10.1007/s12553-021-00531-z>
- [19] S. ARSLANKAYA and M. T. ÇELİK, "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, pp. 1–8, 3 2021. [Online]. Available: <http://dergipark.org.tr/en/doi/10.22399/ijcesen.837731>
- [20] J. Atallah, M. C. G. Corcia, and E. P. Walsh, "Ventricular arrhythmia and life-threatening events in patients with repaired tetralogy of fallot," *The American Journal of Cardiology*, vol. 132, pp. 126–132, 10 2020. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S0002914920306822>
- [21] J. Rodriguez, S. Schulz, B. F. Giraldo, and A. Voss, "Risk stratification in idiopathic dilated cardiomyopathy patients using cardiovascular coupling analysis," *Frontiers in Physiology*, vol. 10, 7 2019. [Online]. Available: <https://www.frontiersin.org/article/10.3389/fphys.2019.00841/full>
-

-
- [22] A. Lyon, R. Ariga, A. Minchol , M. Mahmood, E. Ormondroyd, P. Laguna, N. de Freitas, S. Neubauer, H. Watkins, and B. Rodriguez, "Distinct ecg phenotypes identified in hypertrophic cardiomyopathy using machine learning associate with arrhythmic risk markers," *Frontiers in Physiology*, vol. 9, 3 2018.
- [23] D. R. Okada, J. Miller, J. Chrispin, A. Prakosa, N. Trayanova, S. Jones, M. Maggioni, and K. C. Wu, "Substrate spatial complexity analysis for the prediction of ventricular arrhythmias in patients with ischemic cardiomyopathy," *Circulation: Arrhythmia and Electrophysiology*, vol. 13, 4 2020. [Online]. Available: <http://dx.doi.org/10.1161/CIRCEP.119.007975>
- [24] K. Nakajima, T. Nakata, T. Doi, H. Tada, and K. Maruyama, "Machine learning-based risk model using 123i-metaiodobenzylguanidine to differentially predict modes of cardiac death in heart failure," *Journal of Nuclear Cardiology*, vol. 29, pp. 190–201, 2 2022. [Online]. Available: <http://dx.doi.org/10.1007/s12350-020-02173-6>
- [25] L. F. Sotto, R. C. Coelho, and V. V. de Melo, "Classification of cardiac arrhythmia by random forests with features constructed by kaizen programming with linear genetic programming," in *Proceedings of the Genetic and Evolutionary Computation Conference 2016*, ser. GECCO '16. New York, NY, USA: Association for Computing Machinery, 2016, p. 813–820. [Online]. Available: <https://doi.org/10.1145/2908812.2908882>
- [26] A. El-Geneidy, S. Mukherjee, and A. Darwiche, "Prediction of sudden cardiac death using ensemble classifiers," pp. 677–692, 2021. [Online]. Available: http://dx.doi.org/10.1007/978-3-030-73103-8_48
- [27] J. M. Oliver, P. Gallego, A. E. Gonzalez, P. Avila, A. Alonso, D. Garcia-Hamilton, R. Peinado, L. Dos-Subir , A. Pijuan-Domenech, J. Rueda, M.-J. Rodriguez-Puras, R. Garcia-Orta, E. Mart nez-Quintana, T. Datino, F. Fernandez-Aviles, and J. Bermejo, "Predicting sudden cardiac death in adults with congenital heart disease," *Heart*, vol. 107, pp. 67–75, 1 2021. [Online]. Available: <https://doi.org/10.1136/heartjnl-2020-316791>
- [28] H. Fujita, U. R. Acharya, V. K. Sudarshan, D. N. Ghista, S. V. Sree, L. W. J. Eugene, and J. E. Koh, "Sudden cardiac death (scd) prediction based on nonlinear heart rate variability features and scd index," *Applied Soft Computing*, vol. 43, pp. 510–519, 6 2016. [Online]. Available: <https://dx.doi.org/10.1016/j.asoc.2016.02.049>
- [29] C. U. Kumari, A. S. D. Murthy, B. L. Prasanna, M. P. P. Reddy, and A. K. Panigrahy, "An automated detection of heart arrhythmias using machine learning technique: Svm," *Materials Today: Proceedings*, vol. 45, pp. 1393–1398, 2021. [Online]. Available: <https://dx.doi.org/10.1016/j.matpr.2020.07.088>
- [30] S. Pereira and D. Karia, "Prediction of sudden cardiac death using classification and regression tree model with coalesced based ecg and clinical data." IEEE, 10 2018, pp. 678–681. [Online]. Available: <https://dx.doi.org/10.1109/CESYS.2018.8723979>
- [31] R. Devi, H. K. Tyagi, and D. Kumar, "Early stage prediction of sudden cardiac death." IEEE, 3 2017, pp. 2005–2008. [Online]. Available: <https://dx.doi.org/10.1109/WISPNET.2017.8300112>
-

- [32] M. Shi, H. He, W. Geng, R. Wu, C. Zhan, Y. Jin, F. Zhu, S. Ren, and B. Shen, "Early detection of sudden cardiac death by using ensemble empirical mode decomposition-based entropy and classical linear features from heart rate variability signals," *Frontiers in Physiology*, vol. 11, 2 2020. [Online]. Available: <https://dx.doi.org/10.3389/fphys.2020.00118>
- [33] O. Vargas-Lopez, J. P. Amezcuita-Sanchez, J. J. De-Santiago-Perez, J. R. Rivera-Guillen, M. Valtierra-Rodriguez, M. Toledano-Ayala, and C. A. Perez-Ramirez, "A new methodology based on emd and nonlinear measurements for sudden cardiac death detection," *Sensors*, vol. 20, p. 9, 12 2019. [Online]. Available: <https://dx.doi.org/10.3390/s20010009>
- [34] M. Martinez-Alanis, E. Bojorges-Valdez, N. Wessel, and C. Lerma, "Prediction of sudden cardiac death risk with a support vector machine based on heart rate variability and heartprint indices," *Sensors*, vol. 20, p. 5483, 9 2020. [Online]. Available: <https://dx.doi.org/10.3390/s20195483>
- [35] E. Ebrahimzadeh, M. S. Manuchehri, S. Amoozegar, B. N. Araabi, and H. Soltanian-Zadeh, "A time local subset feature selection for prediction of sudden cardiac death from ecg signal," *Medical and Biological Engineering and Computing*, vol. 56, pp. 1253–1270, 7 2018. [Online]. Available: <https://dx.doi.org/10.1007/s11517-017-1764-1>
- [36] M. Bhattacharya, D.-Y. Lu, S. M. Kudchadkar, G. V. Greenland, P. Lingamaneni, C. P. Corona-Villalobos, Y. Guan, J. E. Marine, J. E. Olgin, S. Zimmerman, T. P. Abraham, H. Shatkay, and M. R. Abraham, "Identifying ventricular arrhythmias and their predictors by applying machine learning methods to electronic health records in patients with hypertrophic cardiomyopathy (hcm-var-risk model)," *The American Journal of Cardiology*, vol. 123, pp. 1681–1689, 5 2019. [Online]. Available: <https://dx.doi.org/10.1016/j.amjcard.2019.02.022>
- [37] C. C. Fajas, L. U. González, and J. I. P. de Viñaspre, "Síndrome de qt largo secundario a fluoxetina," *Medicina de Familia. SEMERGEN*, vol. 44, pp. 66–68, 1 2018.
- [38] W. Leyton and C. López, *Manual de signos vitales en la población pediátrica*. Editorial Universidad de Los Lagos, 11 2020. [Online]. Available: <http://editorial.ulagos.cl/wp-content/uploads/2021/04/Manual-de-signos-vitales-en-la-poblacion-pediatrica.pdf>
- [39] S. Fleming, M. Thompson, R. Stevens, C. Heneghan, A. Plüddemann, I. Maconochie, L. Tarassenko, and D. Mant, "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, pp. 1011–1018, 3 2011. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S014067361062226X>
- [40] A. B. de Luna and R. Elosua, "Muerte súbita," *Revista Española de Cardiología*, vol. 65, pp. 1039–1052, 11 2012.
- [41] M. F. Márquez, "El síndrome de qt largo: una breve revisión del diagnóstico electrocardiográfico incluyendo la prueba de viskin," *Archivos de Cardiología de México*, vol. 82, pp. 243–247, 7 2012. [Onli-
-

- ne]. Available: [http://www.archivoscardiologia.com/previos/\(2012\)%20ACM%20Vol%2082.%203%20JULIO-SEPTIEMBRE/ACMX_2012_82_3_243-247.pdf](http://www.archivoscardiologia.com/previos/(2012)%20ACM%20Vol%2082.%203%20JULIO-SEPTIEMBRE/ACMX_2012_82_3_243-247.pdf)
- [42] P. B. Amador, R. C. León, and E. D. Infante, "Significado clínico y pronóstico de las arritmias ventriculares," *Cardiocre*, vol. 51, pp. 91–94, 7 2016.
- [43] M. Retana-Puigmartí, E. D. Frutos-Echaniz, I. Castro-Acuña-Baixaui, and A. Val-Jimenez, "Diagnosticar un síndrome de brugada: el papel de la atención primaria," *SEMERGEN - Medicina de Familia*, vol. 37, pp. 569–572, 12 2011. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S113835931100267X>
- [44] F. Hornero and J. Almendral, "Arritmias ventriculares. aspectos generales," *Cirugía Cardiovascular*, vol. 17, pp. 219–229, 10 2010. [Online]. Available: <https://linkinghub.elsevier.com/retrieve/pii/S1134009610700966>
-