

**Indagar mortalidad prematura por enfermedad cardiovascular: enfoque integrado de  
sistemas inteligentes y ciencia de datos**

Mancilla Mosquera, Ingry Yuleima

Asesor

Anillo Arrieta, Luis Angel

Universidad Nacional Abierta y a Distancia UNAD  
Escuela de Ciencias Básicas, Tecnología e Ingeniería ECBTI  
Ciencia de Datos y Analítica

2024

## **Agradecimientos**

Agradecida inmensamente con Dios, quien me ha brindado sabiduría y fortaleza en todo momento. A mi familia, pilares inquebrantables de apoyo y amor; su constante aliento y comprensión me impulsaron a seguir adelante en los momentos más difíciles. Extiendo este agradecimiento a mis asesores, su experiencia, orientación y paciencia fueron fundamentales en cada etapa de este trabajo; Al universo, por conspirar a mi favor para estar hoy en este momento de la vida, por brindarme la oportunidad de aprender y crecer profesionalmente. Cada observación de mejora fue una oportunidad de crecimiento, y cada logro, un motivo de alegría.

## Resumen

El sector salud enfrenta desafíos en la prevención y atención de muerte prematura por enfermedad cardiovascular a nivel mundial, especialmente debido a la dependencia de métodos clínicos tradicionales que necesitan ser complementados y optimizados con sistemas inteligentes más avanzados. Los recientes avances tecnológicos, como el uso de lenguajes de programación y el procesamiento de grandes volúmenes de datos en tiempo real, ofrecen la oportunidad de proponer estrategias innovadoras basadas en sistemas inteligentes y ciencia de datos, en pro de reducir la mortalidad prematura en mujeres por enfermedades cardiovasculares.

De acuerdo con Pepió, la identificación de estrategias, el desarrollo y la implementación de las mismas por profesionales capacitado, generará un impacto significativamente positivo en la práctica clínica, para mejorar la detección temprana de enfermedades cardiovasculares en mujeres. En este contexto, la presente monografía tiene como objetivo principal plantear dichas estrategias, de manera que posteriormente puedan ser desarrolladas y aplicadas por expertos de diversas disciplinas involucradas en el tratamiento de enfermedades cardiovasculares. En el marco conceptual y teórico se identifican las variables que influyen en la mortalidad prematura de mujeres por enfermedades cardiovasculares, así como las aplicaciones existentes de sistemas inteligentes y ciencia de datos que emplean modelos estadísticos para la predicción de estas enfermedades. A partir de estas anotaciones, se proponen estrategias integradas en el ámbito de los sistemas inteligentes y la ciencia de datos que contribuyan a reducir esta problemática.

***Palabras clave:*** Sistemas Inteligentes, Ciencia de Datos, Modelos Estadísticos, Enfermedad Cardiovascular, mujeres

## Abstract

The health sector faces challenges in the prevention and care of premature death from cardiovascular disease worldwide, especially due to the reliance on traditional clinical methods that need to be complemented and optimized with more advanced intelligent systems. Recent technological advances, such as the use of programming languages and real-time processing of large volumes of data, offer the opportunity to propose innovative strategies based on intelligent systems and data science to reduce premature mortality in women from cardiovascular disease.

According to Pepió, the identification of strategies, their development and implementation by trained professionals will have a significantly positive impact on clinical practice to improve early detection of cardiovascular disease in women. In this context, the main objective of this monograph is to present these strategies so that they can be subsequently developed and applied by experts from various disciplines involved in the treatment of cardiovascular diseases. The conceptual and theoretical framework identifies the variables that influence premature mortality in women due to cardiovascular diseases, as well as the existing applications of intelligent systems and data science that employ statistical models for the prediction of these diseases. Based on these annotations, integrated strategies in the field of intelligent systems and data science are proposed to help reduce this problem.

**Keywords:** Intelligent Systems, Data Science, Statistical Modeling, Cardiovascular Disease, Women

## Tabla de Contenido

Glosario.....	10
Planteamiento del Problema .....	14
Justificación .....	17
Objetivo General .....	18
Objetivos Específicos.....	18
Marco Conceptual y Teórico .....	19
Variables que Intervienen en la Mortalidad Prematura de Mujeres por Enfermedad	
Cardiovascular .....	20
Hipertensión .....	20
Dislipidemias.....	20
Diabetes Mellitus.....	20
Tabaquismo .....	20
Sedentarismo .....	20
Obesidad.....	21
Edad.....	21
Estrés y Factores Psicosociales .....	21
Factores Genéticos .....	21
Acceso y calidad en los Servicios de Salud .....	21
Sistemas Inteligentes.....	21
Ciencia de Datos .....	22
Aplicaciones Existentes de Sistemas Inteligentes y Ciencia de Datos que Utilizan Modelos	
Estadísticos en la Predicción de Enfermedad Cardiovascular .....	31
Árboles de Decisión .....	33

Máquinas de Vectores de Soporte (SVM).....	34
Asignación de Coeficientes a Cada Variable .....	38
Transformación de Variables Categóricas .....	39
Cálculo de la Función Lineal .....	39
Aplicación de la Función Logística.....	39
Interpretación de los Resultados .....	40
Interpretación de Resultados .....	42
Valores del Paciente.....	43
Modelo Propietario.....	45
Complejidad del Modelo.....	45
Actualizaciones Constantes.....	45
Estrategias en el Marco de los Sistemas Inteligentes y la Ciencia de Datos que Ayuden a la Disminución de la Mortalidad Prematura en Mujeres por Enfermedad Cardiovascular .....	60
Algoritmos de Machine Learning Mejorados y Factores Genéticos (Estrategia Uno) .....	60
Evaluación del Estrés y Factores Psicosociales (Estrategia Dos) .....	62
Lenguajes de Programación Modernos para Modelos Personalizados (Estrategia Tres) .....	65
Modelos de Supervivencia Multivariantes (Estrategia Cuatro) .....	69
Calidad y Acceso a Servicios de Salud (Estrategia Cinco).....	71
Actualización de Datos y Continuidad (Estrategia Siete).....	79
Facilidad de Uso y Accesibilidad (Estrategia Ocho) .....	80
Validación en Diversas Poblaciones (Estrategia Nueve).....	80
Conclusiones .....	82
Recomendaciones .....	83

Referencias Bibliográficas ..... 84

## Lista de Tablas

<b>Tabla 1</b> <i>Variables que Influyen en las Enfermedades Cardiovasculares</i> .....	23
<b>Tabla 2</b> <i>Aplicaciones Existentes de Sistemas Inteligentes y Ciencia de Datos</i> .....	46
<b>Tabla 3</b> <i>Opiniones de PAHO/WHO Cardiovascular Risk Calculator</i> .....	53
<b>Tabla 4</b> <i>Opiniones de la Aplicación DECardio 2</i> .....	54
<b>Tabla 5</b> <i>Opiniones de la Aplicación Calculadora RCV de la SEC</i> .....	56
<b>Tabla 6</b> <i>Opiniones de las Aplicaciones Restantes Detalladas en el Informe</i> .....	56
<b>Tabla 7</b> <i>Comparación y Beneficios de la Estrategia uno</i> .....	60
<b>Tabla 8</b> <i>Comparación y Beneficios de la Estrategia dos</i> .....	63
<b>Tabla 9</b> <i>Comparación y Beneficios de la Estrategia tres</i> .....	65
<b>Tabla 10</b> <i>Comparación y Beneficios de la Estrategia cuatro</i> .....	69
<b>Tabla 11</b> <i>Comparación y Beneficios de la Estrategia cinco</i> .....	72
<b>Tabla 12</b> <i>Comparación y Beneficios de la Estrategia seis</i> .....	76

## Lista de Figuras

<b>Figura 1</b> <i>Ejemlo Calculadora ASCVD Risk Estimator Plus .....</i>	45
<b>Figura 2</b> <i>Porcentaje de Utilizacion de las Apicaciones Detalladas en este Informe.....</i>	52
<b>Figura 3</b> <i>Diagrama de Flujo para el Desarrollo de la Estrategia Ino .....</i>	62
<b>Figura 4</b> <i>Diagrama de Flujo para Recopilar Información de laEstrategia Dos .....</i>	64
<b>Figura 5</b> <i>Diagrama de Flujo para el Desarrollo de la Estrategia Dos .....</i>	65
<b>Figura 6</b> <i>Diagrama de Flujo para el Desarrollo de la Estrategia Tres .....</i>	68
<b>Figura 7</b> <i>Diagrama de Flujo para el Desarrollo de laEstrategia Cuatro .....</i>	71
<b>Figura 8</b> <i>Diagrama de Flujo para el Desarrollo de la EstrategiaCcinco .....</i>	74
<b>Figura 9</b> <i>Diagrama de Flujo para el Desarrollo de la Estrategia Seis .....</i>	78
<b>Figura 10</b> <i>Diagrama de Flujo para el Desarrollo de la Estrategia Siete.....</i>	79
<b>Figura 11</b> <i>Diagrama de Flujo para el Desarrollo de la Estrategia Ocho.....</i>	80
<b>Figura 12</b> <i>Diagrama de Flujo para el Desarrollo de la Estrategia Nueve .....</i>	81

## Glosario

**ANN (Artificial Neural Networks):** Modelo computacional inspirado en las redes neuronales biológicas, utilizado en inteligencia artificial para realizar tareas complejas como la predicción de enfermedades.

**ASCVD (Atherosclerotic Cardiovascular Disease):** Enfermedad cardiovascular causada por la acumulación de placas de grasa en las arterias, incluyendo ataques al corazón y derrames cerebrales.

**Ciencia de Datos:** Disciplina que combina métodos estadísticos, algoritmos de aprendizaje automático y análisis de grandes volúmenes de datos para descubrir patrones y generar conocimientos útiles en diversas áreas, incluida la salud.

**Colesterol:** Sustancia grasa presente en el organismo, esencial para funciones celulares pero que, en niveles elevados, puede contribuir al desarrollo de enfermedades cardiovasculares.

**Dislipidemias:** Alteraciones en los niveles de lípidos en la sangre, como colesterol y triglicéridos, que aumentan el riesgo de desarrollar enfermedades cardiovasculares.

**Diabetes Mellitus:** Enfermedad crónica caracterizada por niveles elevados de glucosa en sangre debido a problemas en la producción o utilización de insulina.

**Enfermedad Cardiovascular (ECV):** Conjunto de trastornos que afectan el corazón y los vasos sanguíneos, como la cardiopatía isquémica, los accidentes cerebrovasculares y la hipertensión.

**ESC (European Society of Cardiology):** Organización profesional que promueve la excelencia en la investigación, prevención y manejo de enfermedades cardiovasculares en Europa.

**Factores genéticos:** Características hereditarias que predisponen a las personas a desarrollar ciertas enfermedades, incluidas las cardiovasculares.

**HDL (High-Density Lipoprotein):** Conocido como "colesterol bueno", es una lipoproteína que ayuda a remover el exceso de colesterol de las arterias y transportarlo al hígado.

**Hipertensión:** Condición crónica en la que la presión arterial está persistentemente elevada, incrementando el riesgo de enfermedades cardiovasculares y renales.

**IMC (Índice de Masa Corporal):** Medida de relación entre el peso y la altura de una persona, utilizada para clasificar el estado nutricional y evaluar riesgos de salud.

**LDL (Low-Density Lipoprotein):** Conocido como "colesterol malo", es una lipoproteína que transporta colesterol a las células pero puede acumularse en las paredes arteriales.

**Modelos Estadísticos:** Herramientas matemáticas utilizadas para analizar datos y establecer relaciones entre variables, frecuentemente aplicados en estudios de predicción y diagnóstico.

**OMS (Organización Mundial de la Salud):** Agencia de las Naciones Unidas dedicada a la promoción de la salud global, el establecimiento de políticas de salud y el monitoreo de tendencias epidemiológicas.

**OPS (Organización Panamericana de la Salud):** Ver PAHO.

**PAHO (Pan American Health Organization):** Organización internacional que trabaja en el ámbito de la salud pública en las Américas, promoviendo políticas de prevención y atención.

**Predicción:** Proceso de estimar o anticipar resultados futuros basados en datos históricos y modelos analíticos, útil en la prevención y manejo de enfermedades.

**Prematura:** Referente a algo que ocurre antes de tiempo. En el contexto de la salud, se refiere a enfermedades o muertes que suceden antes de la edad promedio esperada.

RCV (Riesgo Cardiovascular): Probabilidad de desarrollar enfermedades cardiovasculares en un periodo determinado, influenciado por factores como la edad, el sexo, el tabaquismo y las condiciones metabólicas.

SCORE (Systematic Coronary Risk Evaluation): Herramienta desarrollada por la Sociedad Europea de Cardiología para calcular el riesgo de eventos cardiovasculares fatales en un plazo de 10 años.

SEC (Sociedad Española de Cardiología): Asociación científica dedicada al estudio, prevención y tratamiento de enfermedades cardiovasculares en España.

Sistemas Inteligentes: Conjunto de tecnologías y algoritmos diseñados para simular capacidades humanas como aprendizaje, razonamiento y toma de decisiones, utilizadas en aplicaciones como predicción y diagnóstico médico.

SVM (Support Vector Machines): Algoritmo de aprendizaje automático utilizado para clasificación y regresión, ampliamente empleado en el análisis de datos médicos.

WHO (World Health Organization): Ver OMS.

## Introducción

Las enfermedades cardiovasculares (ECV) constituyen una de las principales causas de mortalidad en todo el mundo, afectando de manera desproporcionada a las mujeres en edad temprana. A pesar de los avances en la detección y el tratamiento de estas enfermedades, la mortalidad prematura en mujeres sigue siendo un desafío global, influenciado por factores genéticos, sociales, psicológicos y de acceso a servicios de salud. Este fenómeno requiere una atención especializada, tanto en términos de investigación como en la implementación de soluciones innovadoras que integren tecnologías avanzadas y enfoques interdisciplinarios.

El propósito de este trabajo es abordar esta problemática a través de la propuesta de estrategias orientadas a la reducción de la mortalidad prematura en mujeres por ECV, utilizando un enfoque integrado de sistemas inteligentes y ciencia de datos. Este enfoque se basa en el análisis de grandes volúmenes de datos, permitiendo identificar patrones y factores de riesgo que, de otra manera, podrían pasar desapercibidos en estudios tradicionales.

Para cumplir este objetivo, se han definido tres líneas de acción específicas: primero, la identificación de las variables más relevantes en la mortalidad prematura por ECV mediante el análisis de estudios de caso, literatura científica y datos históricos; segundo, la exploración de aplicaciones existentes que empleen modelos estadísticos y de predicción basados en sistemas inteligentes para la prevención y manejo de enfermedades cardiovasculares; y tercero, la formulación de un conjunto de estrategias que integren estas tecnologías con un enfoque práctico y aplicable en contextos diversos.

Con este enfoque, esta monografía busca no solo contribuir al conocimiento existente sobre las ECV en mujeres, sino también ofrecer ese camino inicial para concretar la prevención y el tratamiento, reduciendo así la carga de estas enfermedades en la sociedad.

## Planteamiento del Problema

Según datos recientes de la Organización Mundial de la Salud (OMS), las enfermedades cardiovasculares (ECV) siguen siendo la principal causa de muerte en el mundo, con aproximadamente 17.9 millones de fallecimientos en 2019 (aún hoy 2024), lo que representa alrededor del 32% de todas las muertes globales. De estas, más de un tercio son consideradas prematuras, es decir, ocurren en personas menores de 70 años; el 85% se debieron a infartos de miocardio y accidentes cerebrovasculares, y más del 75% ocurrieron en países de ingresos bajos y medianos. Para 2023, estudios adicionales sugieren un incremento en la mortalidad por ECV en algunas regiones, lo que subraya la importancia de abordar factores de riesgo como la hipertensión, el tabaquismo y la mala alimentación para reducir este impacto global.

Aunque la mortalidad por ECV afecta tanto a hombres como a mujeres, las mujeres presentan factores de riesgo únicos, como la preeclampsia, la menopausia temprana y condiciones inflamatorias crónicas, que aumentan el riesgo de enfermedades cardiovasculares en edades más tempranas (Ouyang et al., 2022). Además, el síndrome de ovario poliquístico (SOP) y el lupus son afecciones que también se han relacionado con un mayor riesgo cardiovascular en mujeres jóvenes (Reis et al., 2023).

Las mujeres con enfermedades cardiovasculares suelen ser diagnosticadas más tarde que los hombres debido a diferencias en los síntomas, lo cual contribuye a una mayor mortalidad prematura (Mosca et al., 2021). Esto incluye que las mujeres, por lo general, presentan síntomas más atípicos y que el personal médico puede subestimar su riesgo cardiovascular (Sampson & Gooding, 2020). Tradicionalmente, las investigaciones sobre ECV se han centrado en muestras predominantemente masculinas, lo que ha llevado a una falta de conocimiento específico sobre cómo prevenir y tratar las enfermedades cardiovasculares en mujeres (Anderson et al., 2023).

Entendiendo entonces que las enfermedades cardiovasculares constituyen la principal causa de muerte en el mundo, y afectan en mayor medida a las mujeres (Bustamante, et al., 2020); y que las personas están utilizando el internet para automedicarse (Masson, et al., 2015), se plantea esta monografía enmarcada en la cadena de formación en sistemas, enfocada a la línea de investigación de sistemas inteligentes, buscando proponer estrategias que permitan mejorar la detección temprana de enfermedades cardiovasculares en mujeres y a su vez cumplir con el requisito de desarrollar la propuesta de trabajo de grado planteada para la especialización en ciencia de datos y analítica.

Las enfermedades cardiovasculares prematuras impactan significativamente a nivel mundial, por ende, ha de considerarse un problema de salud pública (Rosa Bordón & Saldaña de Gutiérrez, 2017), que tiene consecuencias no solo para las personas, sino también al sistema de atención médica y al sector de seguros. Aún con los avances logrados en el tratamiento de las enfermedades cardiovasculares, la identificación temprana de los factores de riesgo y la predicción de la mortalidad prematura, siguen siendo motivo de investigación.

No es de negar que resulta complejo plantear estrategias que aporten a encontrar mecanismos óptimos para mejorar la detección oportuna de esta enfermedad, teniendo en cuenta la información tan variable y de diferentes Notas con la que nos encontramos en cada paciente (Martínez, 2014), incluyendo aspectos legales en el tratamiento de la información con la que se trabaja.

En consecuencia, a lo anterior y considerando que abordar la mortalidad prematura por enfermedad cardiovascular requiere de aportes constantes y novedosos de las diferentes disciplinas, cabe preguntar ¿Qué estrategias, pueden ayudar a la disminución de la mortalidad prematura en mujeres por Enfermedad Cardiovascular, aplicando un enfoque integrado de

sistemas inteligentes y ciencia de datos?; esta monografía propone indagar sobre los factores que ponen en riesgo la salud de las personas de adquirir esta enfermedad, el uso de sistemas inteligentes y la ciencia de datos para ayudar a la predicción y la gestión de la mortalidad prematura por enfermedad cardiovascular (Gómez, 2017), con intención de mejorar la salud cardiovascular y la calidad de vida de las familias.

## Justificación

Las enfermedades cardiovasculares representan una de las principales causas de muerte a nivel mundial (Bustamante, et al., 2020), y la mortalidad prematura por estas enfermedades es preocupante debido a su incidencia en individuos jóvenes y aparentemente sanos. Por lo tanto, comprender los factores causales y proponer estrategias que ayuden a disminuir la mortalidad prematura por enfermedad cardiovascular es fundamental para mejorar los resultados de salud cardiovascular.

El enfoque integrado de sistemas inteligentes y ciencia de datos ofrece una perspectiva prometedora para abordar esta problemática. Los sistemas inteligentes, permiten analizar datos de manera eficiente y descubrir patrones complejos que pueden ser difíciles de identificar con métodos convencionales (Bonventi, 2015). Por otro lado, la ciencia de datos apoyada en otras disciplinas se encarga del análisis de grandes volúmenes de datos para la toma de decisiones (Valdovinos, 2023)

Al integrar los sistemas inteligentes con la ciencia de datos, podemos aprovechar la información disponible en el ámbito de la salud para proponer estrategias de utilización de modelos estadísticos (Madrigal et al., 2023), precisos y personalizados que puedan identificar a las mujeres en mayor riesgo de mortalidad prematura por enfermedad cardiovascular.

El resultado de esta monografía puede tener un impacto significativo en la práctica clínica (Pepió, 2019); después de que las estrategias planteadas para mejorar la detección temprana de adquirir enfermedad cardiovascular en mujeres, sea implementada y probada por personal idóneo con la intervención de las diferentes disciplinas implicadas en el tratamiento de esta enfermedad.

## **Objetivos**

### **Objetivo General**

Proponer estrategias mediante un enfoque integrado de sistemas inteligentes y ciencia de datos, que ayuden a la disminución de la mortalidad prematura en mujeres por Enfermedad Cardiovascular

### **Objetivos Específicos**

Identificar las variables que intervienen en la mortalidad prematura de mujeres por Enfermedad Cardiovascular, en base a estudios de casos, referentes bibliográficos y datos históricos.

Investigar aplicaciones existentes de sistemas inteligentes y ciencia de datos que utilizan modelos estadísticos en la predicción de enfermedad cardiovascular

Proponer un conjunto de estrategias en el marco de los sistemas inteligentes y la ciencia de datos que ayuden a la disminución de la mortalidad prematura en mujeres por Enfermedad Cardiovascular

### **Marco Conceptual y Teórico**

La enfermedad cardiovascular (ECV) sigue siendo una de las principales causas de mortalidad prematura en todo el mundo, con una carga significativa en términos de salud pública y socioeconómica (Organización Mundial de la Salud [OMS]. (2022)). La aplicación de enfoques integrados, como los sistemas inteligentes y la ciencia de datos, ofrece nuevas oportunidades para abordar este desafío de manera más efectiva.

La enfermedad cardiovascular abarca una serie de trastornos del corazón y los vasos sanguíneos, siendo una de las principales causas de mortalidad prematura a nivel mundial (Lloyd-Jones et al., 2019). La mortalidad prematura por enfermedad cardiovascular está influenciada por una serie de factores de riesgo, incluyendo la hipertensión, la diabetes, el tabaquismo y la obesidad (Benjamin et al., 2019). El impacto de la enfermedad cardiovascular en términos de mortalidad prematura es especialmente alto en países de ingresos bajos y medianos, lo que lleva a la necesidad de validar estrategias efectivas de prevención y control (Roth et al., 2020). Las mujeres tienen un riesgo significativo de morir prematuramente por enfermedad cardiovascular, y esta tendencia está en aumento en algunas poblaciones (Arora et al., 2019).

La integración de sistemas inteligentes y la ciencia de datos, ofrece un enfoque competente para comprender y abordar la mortalidad prematura por enfermedad cardiovascular, teniendo presente todos los factores de riesgo que intervienen en esta enfermedad. Este marco conceptual y teórico proporciona una base sólida para el análisis de información y proponer estrategias que puedan ser implementadas en la práctica clínica.

## **Variables que Intervienen en la Mortalidad Prematura de Mujeres por Enfermedad**

### **Cardiovascular**

En la **Tabla 1** se pueden visualizar las variables que a continuación se detallan, como factores determinantes de la causa de mortalidad prematura en mujeres por enfermedad cardiovascular.

#### ***Hipertensión***

Es uno de los factores de riesgo más importantes, ya que la presión arterial alta daña las arterias y el corazón (Mills, K. T., Stefanescu, A., & He, J., 2020) y tiene una alta prevalencia en mujeres de mediana edad (Cheng, C., & Hong, L. 2019).

#### ***Dislipidemias***

Las alteraciones en los niveles de colesterol y triglicéridos son un importante predictor de riesgo cardiovascular en mujeres (Miller, M., & Stone, N. J. 2018).

#### ***Diabetes Mellitus***

Las mujeres con diabetes tienen un riesgo considerablemente mayor de desarrollar enfermedades cardiovasculares en comparación con los hombres (Peters, S. A. E., & Woodward, M. 2018).

#### ***Tabaquismo***

El tabaquismo en mujeres incrementa significativamente el riesgo de enfermedad cardiovascular, especialmente en las más jóvenes Huxley, R. R., & Woodward, M. (2019).

#### ***Sedentarismo***

La falta de actividad física aumenta significativamente el riesgo de enfermedades del corazón (Lavie, C. J., O'Keefe, J. H., & Sallis, R. E. 2015) y contribuye al desarrollo de factores

de riesgo como la obesidad, la hipertensión y la dislipidemia (Warburton, D. E., & Bredin, S. S. 2017).

### ***Obesidad***

La obesidad, en particular la abdominal, es un factor de riesgo significativo para las enfermedades cardiovasculares en mujeres (Okura, T., Nakata, Y., & Matsuo, T. 2017).

### ***Edad***

La edad es un factor de riesgo clave, ya que las probabilidades de desarrollar enfermedades cardiovasculares aumentan con la edad, especialmente en mujeres postmenopáusicas (Ma, Y., Li, Y., & Wang, X. 2020).

### ***Estrés y Factores Psicosociales***

El estrés crónico y los trastornos psicológicos como la depresión se asocian con un mayor riesgo de enfermedades cardiovasculares en mujeres (Vaccarino, V., & Abramson, J. L. 2016).

### ***Factores Genéticos***

La predisposición genética puede influir en la susceptibilidad de las mujeres a enfermedades cardiovasculares (Smith, D. J., & Jones, T. M. 2018).

### ***Acceso y calidad en los Servicios de Salud***

Las disparidades en el acceso a servicios de salud de calidad pueden influir en la mortalidad por enfermedades cardiovasculares (Mosca, L., Barrett-Connor, E., & Wenger, N. K. 2018).

### **Sistemas Inteligentes**

Un sistema inteligente es un conjunto de algoritmos, tecnologías y herramientas que permiten a una máquina o software tomar decisiones autónomas o asistidas con base en datos y aprendizajes previos. Estos sistemas pueden adaptarse a cambios en el entorno y mejorar su

rendimiento mediante técnicas de inteligencia artificial (IA), como el aprendizaje automático (machine learning), la lógica difusa o las redes neuronales. En el contexto médico, los sistemas inteligentes se utilizan para procesar grandes volúmenes de datos clínicos, identificar patrones, hacer recomendaciones de tratamiento o diagnosticar enfermedades con base en los síntomas y registros históricos de los pacientes (Russell & Norvig, 2021).

Los sistemas inteligentes, como el aprendizaje automático y la inteligencia artificial, tienen el potencial de mejorar la prevención, el diagnóstico y el tratamiento de enfermedades cardiovasculares al aprovechar grandes conjuntos de datos clínicos y biomédicos (Topol, 2019). La aplicación de algoritmos de aprendizaje automático en conjuntos de datos de salud de las mujeres puede identificar patrones de enfermedad cardiovascular específicos del género y mejorar la precisión del pronóstico (Gehi et al., 2021).

### **Ciencia de Datos**

La ciencia de datos es un campo interdisciplinario que utiliza técnicas matemáticas, estadísticas y de computación para extraer conocimientos útiles a partir de grandes volúmenes de datos (proviene de múltiples Notas). Los científicos de datos emplean diversas herramientas, como algoritmos de aprendizaje automático y métodos estadísticos, para identificar patrones, hacer predicciones y mejorar la toma de decisiones en áreas como la salud, la economía y la industria. En el ámbito de la predicción de enfermedades, la ciencia de datos puede ser utilizada para analizar registros médicos, identificar factores de riesgo y predecir la probabilidad de desarrollo de enfermedades cardiovasculares mediante modelos predictivos (Provost & Fawcett, 2013).

La ciencia de datos proporciona herramientas y métodos para analizar grandes volúmenes de datos de manera eficiente y extraer conocimientos significativos sobre la enfermedad

cardiovascular y sus determinantes (Krumholz, 2020). El análisis de datos multimodales, que integra información clínica, genómica, ambiental y socioeconómica, puede proporcionar una comprensión más completa de los factores que contribuyen a la mortalidad prematura por enfermedad cardiovascular (Collins & Varmus, 2015).

La integración de datos multimodales (mayor frecuencia de un conjunto de datos) mediante técnicas de ciencia de datos permite una evaluación holística de los factores de riesgo cardiovascular y su asociación con la mortalidad prematura, mejorando la capacidad predictiva y explicativa de los modelos (Gallo et al., 2020). Los desafíos en la integración de datos multimodales incluyen la estandarización de formatos, la interoperabilidad entre sistemas y la protección de la privacidad de los datos, que deben abordarse para maximizar su utilidad clínica y epidemiológica (Kern et al., 2019).

### **Tabla 1**

#### *Variables que Influyen en las Enfermedades Cardiovasculares*

Variable	Autor	Año	Descripción y Relevancia
Hipertensión	Mills et al.	2020	La presión arterial alta daña las arterias y el corazón, con alta prevalencia en mujeres de mediana edad.

---

			La hipertensión afecta desproporcionadamente a mujeres, especialmente en la menopausia, cuando los cambios hormonales aumentan la probabilidad de hipertensión sostenida. Este factor se asocia con daño en órganos como el corazón, cerebro y riñones, intensificando el riesgo cardiovascular
	Cheng & Hong	2019	
Dislipidemias	Miller & Stone	2018	Alteraciones en colesterol y triglicéridos predicen riesgos cardiovasculares en mujeres. Las mujeres con diabetes tienen un riesgo mayor de enfermedad cardiovascular en comparación con los hombres.
Diabetes mellitus	Peters & Woodward	2018	Incrementa significativamente el riesgo cardiovascular, especialmente en mujeres jóvenes.
Tabaquismo	Huxley & Woodward	2019	

---

---

			La falta de actividad física aumenta el riesgo de enfermedades del corazón y promueve otros factores como obesidad e hipertensión.
	Lavie et al.	2015	El sedentarismo contribuye significativamente al desarrollo de factores de riesgo como obesidad, hipertensión, y dislipidemia, todos ellos estrechamente ligados a enfermedades cardíacas. La
Sedentarismo			inactividad física afecta negativamente la salud cardiovascular al reducir la capacidad funcional y la resistencia del corazón y los vasos sanguíneos
	Warburton & Bredin	2017	La obesidad abdominal es un factor de riesgo significativo para enfermedades cardiovasculares en mujeres.
Obesidad	Okura et al.	2017	

---

---

Edad	Ma et al.	2020	El riesgo cardiovascular aumenta con la edad, especialmente en mujeres postmenopáusicas.
Estrés y factores psicosociales	Vaccarino & Abramson	2016	El estrés crónico y la depresión se asocian con mayor riesgo cardiovascular.
Factores genéticos	Smith & Jones	2018	La predisposición genética influye en la susceptibilidad de las mujeres a enfermedades cardiovasculares.
Acceso y calidad en servicios de salud	Mosca et al.	2018	Las disparidades en el acceso a servicios de calidad pueden influir en la mortalidad cardiovascular.
Sistemas inteligentes	Russell & Norvig	2021	Aplicación de IA para procesar datos clínicos y mejorar prevención, diagnóstico y tratamiento de enfermedades cardiovasculares.

---

Topol

2019

---

Son herramientas avanzadas que combinan algoritmos de aprendizaje automático y grandes volúmenes de datos para evaluar el riesgo de enfermedades cardiovasculares. Estos sistemas permiten un análisis detallado de factores genéticos, biométricos y conductuales en tiempo real, proporcionando evaluaciones personalizadas y precisas. Su relevancia radica en su capacidad para detectar patrones que podrían pasar inadvertidos en los métodos tradicionales, facilitando la predicción y prevención temprana de eventos cardíacos. Así, estos sistemas promueven una medicina más proactiva y personalizada, mejorando potencialmente la calidad de vida y reduciendo la

---

Ciencia de datos

Provost & Fawcett

2013

Herramientas de análisis para integrar datos clínicos y ambientales, permitiendo evaluaciones predictivas y explicativas de factores de riesgo cardiovascular en mujeres.

---

---

Krumholz	2020	<p>La ciencia de datos facilita el uso de modelos predictivos personalizados que integran información clínica, genética y del estilo de vida, ofreciendo una evaluación de riesgo precisa para cada individuo. Esta tecnología permite una atención preventiva más efectiva, al identificar a las personas en alto riesgo de manera temprana. Además, ayuda a mejorar la toma de decisiones clínicas y la implementación de intervenciones preventivas personalizadas, reduciendo la carga de enfermedades cardiovasculares en la población.</p>
----------	------	--

---

---

Collins & Varmus

2015

Permite analizar grandes volúmenes de datos clínicos, genéticos y de estilo de vida. Mediante el uso de modelos predictivos avanzados, como el aprendizaje automático, se pueden identificar patrones ocultos que no son evidentes a simple vista. La integración de estos datos facilita la personalización de intervenciones preventivas. Además, el análisis de factores de riesgo multifactoriales mejora la precisión en la predicción y toma de decisiones clínicas.

---

*Nota.* Se describen las variables identificadas que actualmente se tienen en cuenta para predecir las enfermedades cardiovasculares en mujeres.

## **Aplicaciones Existentes de Sistemas Inteligentes y Ciencia de Datos que Utilizan Modelos Estadísticos en la Predicción de Enfermedad Cardiovascular**

En la **Tabla 2** se presentan los hallazgos de las principales aplicaciones de sistemas inteligentes y ciencia de datos que utilizan modelos estadísticos en la predicción de enfermedad cardiovascular, y que se describen a continuación.

Actualmente existen múltiples aplicaciones que se utilizan para determinar la probabilidad de adquirir enfermedad cardio vascular: Calculadora RCV de la Sociedad Española de Cardiología, PAHO/WHO Cardiovascular Risk Calculator, CardioRisk de la Universidad Complutense de Madrid, ASCVD Risk Estimator Plus de la American College of Cardiology Foundation, DECardio 2 (Herrero et al., 2018).

DECardio 2 (Fernández-Obanza et. al., 2018) por ejemplo es una aplicación para profesionales de la cardiología, que basada en el sistema europeo SCORE(Systematic COronary Risk Evaluation) (European Society of Cardiology [ESC], 2022), realiza múltiples funciones, entre ellas calcular el riesgo cardio vascular en función de aspectos clínico como, la edad, el sexo, presión arterial sistólica, presión arterial diastólica, niveles elevados de colesterol (LDL > Malo), niveles bajos de colesterol (HDL > Bueno) , historial clínico(diabetes, tabaquismo, etc), índice de masa corporal IMC (obesidad y sobrepeso basados en la estatura y el peso).

La Sociedad Española de Cardiología (SEC) ha desarrollado una Calculadora de Riesgo Cardiovascular (RCV) que tiene como objetivo evaluar el riesgo de eventos cardiovasculares a 10 años en la población española. Esta herramienta utiliza factores de riesgo específicos y modelos de predicción adaptados a la población española para proporcionar una estimación precisa del riesgo cardiovascular en individuos adultos (Sociedad Española de Cardiología [SEC], s.f.).

La RCV de la SEC incluye factores de riesgo como la edad, el sexo, la presión arterial sistólica, el colesterol total, el colesterol HDL, el tabaquismo, la diabetes y el tratamiento con medicamentos antihipertensivos. Estos factores se utilizan para calcular el riesgo absoluto de eventos cardiovasculares graves, como el infarto de miocardio y el accidente cerebrovascular, en los próximos 10 años en la población española (Sociedad Española de Cardiología [SEC], s.f.).

El Calculador de Riesgo Cardiovascular de la OPS/OMS es una herramienta en línea diseñada para evaluar el riesgo de enfermedad cardiovascular en individuos adultos. Utiliza una variedad de factores de riesgo, como la edad, el sexo, la presión arterial, el colesterol total, el colesterol HDL, el tabaquismo y la presencia de diabetes mellitus, para estimar el riesgo de sufrir un evento cardiovascular en los próximos 10 años (Pan American Health Organization/World Health Organization [PAHO/WHO], s.f.).

RiskCalc se basa en el modelo de regresión logística, uno de los enfoques más utilizados para la predicción de eventos binarios. La regresión logística permite modelar la relación entre una variable dependiente dicotómica (por ejemplo, la presencia o ausencia de una enfermedad) y varias variables independientes (factores de riesgo) (Hosmer et al., 2013).

El cálculo del riesgo en RiskCalc se realiza mediante la integración de coeficientes estimados a partir de datos históricos del estudio Framingham. La fórmula generada por el modelo de regresión logística en RiskCalc se utiliza para calcular una puntuación de riesgo, que luego se traduce en una estimación de probabilidad.

RiskCalc ha sido validado en diversos estudios y su precisión ha sido confirmada en diferentes poblaciones. La validez externa del modelo es crucial para su aplicación clínica, ya que garantiza que los resultados sean aplicables a una amplia gama de pacientes. Los estudios

han mostrado que RiskCalc tiene una alta capacidad para discriminar entre individuos de alto y bajo riesgo (Kannel et al., 2006).

Aunque RiskCalc es una herramienta poderosa, no está exenta de limitaciones. La precisión del modelo puede verse afectada por la calidad y la disponibilidad de los datos introducidos. Además, el modelo original de Framingham se basa en una población específica, lo que puede limitar la aplicabilidad de RiskCalc en contextos diferentes (Sullivan et al., 2004).

CardioRisk (Blanco, et al., 2017) de la Universidad Complutense de Madrid, ayuda a los profesionales de la salud a calcular el riesgo cardiovascular, y dar soporte para tratamientos; con la información del paciente: presión sanguínea, colesterol, tabaquismo e índice de masa corporal, se calcula el riesgo cardiovascular.

CardioRisk utiliza modelos de regresión logística para predecir la probabilidad de eventos cardiovasculares. Este modelo estadístico es adecuado para manejar variables independientes y proporcionar una estimación de la probabilidad de un evento binario, como la ocurrencia de una enfermedad cardiovascular. La regresión logística en CardioRisk se aplica para integrar factores de riesgo como la edad, el sexo, el colesterol LDL, la presión arterial, el tabaquismo y la presencia de diabetes (Hosmer et al., 2013).

Además de la regresión logística, CardioRisk emplea diversos algoritmos de machine learning para mejorar la precisión de sus predicciones. Entre estos algoritmos se encuentran:

### ***Árboles de Decisión***

Utilizados para clasificar a los pacientes en diferentes categorías de riesgo basadas en una serie de decisiones binarias. Estos modelos permiten la visualización de las decisiones y son útiles para entender las variables que afectan el riesgo cardiovascular (Breiman et al., 1986).

### Bosques Aleatorios (Random Forests)

Un ensamblaje de múltiples árboles de decisión que mejora la precisión y reduce el riesgo de sobreajuste al combinar las predicciones de varios árboles (Liaw & Wiener, 2002).

### *Máquinas de Vectores de Soporte (SVM)*

Utilizadas para clasificar los datos en diferentes categorías de riesgo. SVM es eficaz en la clasificación de datos con alta dimensionalidad y puede manejar tanto datos lineales como no lineales (Cortes & Vapnik, 1995).

CardioRisk también puede utilizar modelos de supervivencia, como el modelo de riesgos proporcionales de Cox, para evaluar el tiempo hasta la ocurrencia de eventos cardiovasculares. Este modelo considera la duración hasta el evento y los factores de riesgo asociados, proporcionando una estimación del riesgo a lo largo del tiempo (Cox, 1972).

CardioRisk se integra en sistemas de registros médicos electrónicos, lo que permite a los profesionales de la salud acceder a datos en tiempo real y utilizar la herramienta para evaluar el riesgo cardiovascular de sus pacientes. La aplicación proporciona recomendaciones personalizadas basadas en las puntuaciones de riesgo calculadas, facilitando la toma de decisiones sobre intervenciones preventivas y tratamientos.

La precisión de los modelos estadísticos utilizados en CardioRisk ha sido validada a través de estudios clínicos y pruebas retrospectivas. La validación asegura que las estimaciones de riesgo sean fiables y aplicables a diferentes poblaciones, mejorando la confianza en las predicciones y la eficacia de las intervenciones basadas en estas predicciones (Bair et al., 2021).

La aplicación ASCVD Risk Estimator Plus, desarrollada por la American College of Cardiology Foundation (American College of Cardiology Foundation, s.f.), es una herramienta innovadora diseñada para evaluar el riesgo de enfermedad cardiovascular aterosclerótica

(ASCVD, por sus siglas en inglés) en individuos adultos. Utilizando una serie de factores de riesgo cardiovascular, como la edad, el sexo, la raza, la presión arterial, los niveles de colesterol y la presencia de diabetes, esta aplicación calcula el riesgo absoluto de sufrir un evento cardiovascular aterosclerótico en los próximos 10 años.

HeartRisk emplea la regresión logística para calcular la probabilidad de eventos cardiovasculares. Este modelo estadístico permite manejar variables independientes y proporciona una estimación de la probabilidad de que un individuo sufra un evento binario, como un ataque al corazón o un accidente cerebrovascular. En HeartRisk, las variables utilizadas en la regresión logística incluyen edad, sexo, presión arterial, niveles de colesterol y hábitos de vida como el tabaquismo (Hosmer et al., 2013).

Los árboles de decisión se utilizan en HeartRisk para clasificar a los pacientes en diferentes niveles de riesgo cardiovascular. Este enfoque proporciona una visualización clara de las decisiones y las características del paciente que contribuyen al riesgo cardiovascular. Los árboles de decisión dividen los datos en ramas basadas en condiciones específicas y generan una clasificación que ayuda a entender cómo diferentes factores de riesgo afectan el riesgo global (Breiman et al., 1986).

HeartRisk utiliza bosques aleatorios para mejorar la precisión de las predicciones. Los bosques aleatorios combinan múltiples árboles de decisión para crear un modelo más robusto y menos propenso al sobreajuste. Este enfoque permite manejar grandes volúmenes de datos con múltiples variables y proporciona una evaluación más precisa del riesgo cardiovascular (Liaw & Wiener, 2002).

Las máquinas de vectores de soporte (SVM) se aplican en HeartRisk para clasificar a los pacientes en categorías de riesgo utilizando un enfoque de margen máximo. Las SVM son

eficaces en la clasificación de datos complejos y de alta dimensión, permitiendo a HeartRisk realizar predicciones precisas incluso en conjuntos de datos con múltiples características y correlaciones (Cortes & Vapnik, 1995).

HeartRisk se integra en los sistemas de registros médicos electrónicos para proporcionar evaluaciones en tiempo real del riesgo cardiovascular. Los profesionales de la salud pueden utilizar esta herramienta para acceder a datos actualizados y personalizar las estrategias de prevención basadas en las estimaciones de riesgo proporcionadas por la aplicación.

La precisión y fiabilidad de HeartRisk se validan mediante estudios retrospectivos y pruebas en diferentes poblaciones. La validación asegura que el modelo pueda generalizarse a una amplia variedad de contextos clínicos y poblaciones, garantizando que las predicciones sean aplicables y útiles en la práctica (Bair et al., 2021).

HeartFlow es un software que combina análisis de imágenes médicas con modelos estadísticos avanzados para la evaluación del riesgo cardiovascular. Utiliza modelos de riesgos proporcionales de Cox para evaluar el flujo sanguíneo en el corazón y determinar la probabilidad de eventos cardiovasculares futuros. La herramienta ofrece resultados en tiempo real y permite a los médicos tomar decisiones informadas sobre intervenciones (Mahoney et al., 2021).

HeartFlow utiliza el modelo de riesgos proporcionales de Cox para analizar la relación entre las características del flujo sanguíneo y el riesgo de eventos cardiovasculares. Este modelo de supervivencia permite evaluar el riesgo de un evento a lo largo del tiempo, teniendo en cuenta factores como la severidad de la obstrucción coronaria y otros parámetros clínicos (Cox, 1972). El modelo de Cox es útil para estimar la probabilidad de eventos cardiovasculares futuros basados en datos de flujo sanguíneo y características individuales del paciente.

HeartFlow también emplea modelos de regresión logística para predecir la probabilidad de eventos cardiovasculares basados en datos de imágenes y flujo sanguíneo. Este modelo ayuda a determinar la relación entre las variables predictoras (como la gravedad de la obstrucción coronaria) y el riesgo de eventos cardiovasculares, proporcionando una estimación probabilística que facilita la toma de decisiones clínicas (Hosmer et al., 2013).

Una parte fundamental del enfoque de HeartFlow es el análisis de imágenes médicas, particularmente tomografías computarizadas de alta resolución. La aplicación utiliza un proceso llamado "análisis de flujo coronario computarizado" para crear un modelo digital del sistema cardiovascular del paciente. Este modelo permite simular el flujo sanguíneo en las arterias coronarias y evaluar la presencia de obstrucciones. El análisis del flujo sanguíneo se combina con modelos estadísticos para proporcionar una evaluación precisa del riesgo cardiovascular (Miller et al., 2015).

HeartFlow integra datos de imágenes médicas con información clínica para proporcionar una evaluación más completa del riesgo cardiovascular. La integración de estos datos permite un análisis más preciso del flujo sanguíneo y de la hemodinámica coronaria. La combinación de datos de imágenes y modelos estadísticos ayuda a personalizar las evaluaciones de riesgo y a desarrollar estrategias de tratamiento basadas en una comprensión detallada del estado cardiovascular del paciente (Pontone et al., 2020).

HeartFlow se implementa en entornos clínicos para proporcionar a los médicos una herramienta avanzada para la evaluación del riesgo cardiovascular. La integración de la aplicación con sistemas de imágenes médicas y registros electrónicos permite una evaluación en tiempo real y facilita la personalización de las estrategias de tratamiento. La herramienta está

diseñada para ayudar a los médicos a identificar pacientes con alto riesgo de eventos cardiovasculares y a planificar intervenciones adecuadas (Miller et al., 2015).

La precisión y la eficacia de HeartFlow se validan a través de estudios clínicos y pruebas retrospectivas. La validación asegura que los modelos estadísticos y las simulaciones de flujo sanguíneo proporcionen estimaciones fiables del riesgo cardiovascular en diferentes poblaciones. Los estudios han demostrado que HeartFlow mejora la precisión en la predicción de eventos cardiovasculares y ayuda a optimizar las decisiones de tratamiento (Mahoney et al., 2021).

Estas aplicaciones utilizan modelos predictivos como el Modelo SCORE, Modelo de Framingham (National Heart, Lung, and Blood Institute, 2022), y Modelo de Reynolds (Ridker, 2007) que incorporan factores de riesgo; de igual manera se utilizan modelos estadísticos como Regresión Logística (Hosmer & Lemeshow, 2013), Análisis de Supervivencia (Cox) (Kleinbaum & Klein, 2012), y Redes Neuronales Artificiales (ANN) (Ahmed et al., 2020), para predecir el riesgo de enfermedad cardiovascular.

Hemos mencionado previamente algunos de los modelos implementados en estas aplicaciones. Se decide explorar un poco más, mostrando cómo algunos modelos utilizan diversas variables para calcular el riesgo cardiovascular, destacando los enfoques y consideraciones clave en la selección y el uso de estas variables en las estimaciones de riesgo.

ASCVD Risk Estimator Plus, para calcular los factores de riesgo cardiovascular utilizan el modelo de regresión logística, siguiendo los siguientes pasos:

#### ***Asignación de Coeficientes a Cada Variable***

Se asigna un coeficiente a cada variable predictora (e.g., edad, sexo, colesterol total, presión arterial sistólica, etc.). Estos coeficientes representan el cambio en el logaritmo de las

probabilidades de presentar enfermedad cardiovascular por cada unidad de cambio en la variable, mientras las demás se mantienen constantes.

### ***Transformación de Variables Categóricas***

VARIABLES como el sexo y la raza se codifican como valores binarios (0 o 1) para permitir que el modelo de regresión logística los interprete. Por ejemplo, el modelo puede distinguir entre hombres y mujeres, y entre afroamericanos y otras etnias, asignando distintos coeficientes a cada categoría.

### ***Cálculo de la Función Lineal***

La regresión logística calcula una combinación lineal de todas las variables, multiplicando cada variable por su respectivo coeficiente y sumando un término de intersección (intercepto) que representa el valor base de la probabilidad. La función lineal se expresa como:

$$\begin{aligned} \text{logit}(p) = & \beta_0 + \beta_1 \cdot \text{Edad} + \beta_2 \cdot \text{Sexo} + \beta_3 \cdot \text{Colesterol Total} + \beta_4 \cdot \text{Colesterol HDL} \\ & + \beta_5 \cdot \text{Presión Arterial Sistólica} + \beta_6 \cdot \text{Tratamiento de Hipertensión} \\ & + \beta_7 \cdot \text{Diagnóstico de Diabetes} + \beta_8 \cdot \text{Hábito de Fumar} + \beta_9 \cdot \text{Raza} \\ & + \beta_{10} \cdot \text{Colesterol LDL} + \beta_{11} \cdot \text{Presión Arterial Diastólica} + \beta_{12} \\ & \cdot \text{Tratamiento con Aspirina} + \beta_{13} \cdot \text{Tratamiento con Estatina} \end{aligned}$$

donde (p) es la probabilidad de desarrollar la enfermedad cardiovascular.

### ***Aplicación de la Función Logística***

Una vez calculada la combinación lineal, el modelo aplica la función logística para transformar esta combinación en una probabilidad entre 0 y 1. La probabilidad de tener un evento cardiovascular se calcula mediante:

$$p = \frac{1}{1 + e^{-\text{logit}(p)}}$$

### ***Interpretación de los Resultados***

El valor de  $p$  representa la probabilidad de que una persona desarrolle enfermedad cardiovascular. Si  $p$  supera un umbral específico, el modelo clasifica al individuo como de alto riesgo de ASCVD

En **RiskCal** por ejemplo, el modelo de Framingham se apoya en la regresión logística para estimar el logaritmo natural de las probabilidades de desarrollar ECV,

así:

$$\log\left(\frac{1-p}{p}\right) = \beta_0 + \beta_1 \cdot \text{edad} + \beta_2 \cdot \text{colesterol} + \beta_3 \cdot \text{presión arterial} + \beta_4 \cdot \text{sexo} + \beta_5 \cdot \text{tabaquismo}$$

$\text{logit}\left(\log\left(\frac{1-p}{p}\right)\right)$ : Es el logaritmo de las probabilidades de que el evento ocurra frente a que no

ocurra. Si el logit es positivo,  $p$  es mayor a 0.5; si es negativo,  $p$  es menor a 0.5.

$p$ : Representa la probabilidad de tener una enfermedad cardiovascular.

Los Coeficientes  $\beta_0, \beta_1, \beta_2, \beta_3, \beta_4$  y  $\beta_5$  :

$\beta_0$  es la constante del modelo (intercepto).

$\beta_1$  es el coeficiente asociado con la edad. Indica cómo varía el logit por cada año de aumento en la edad, manteniendo las demás variables constantes.

$\beta_2$  es el coeficiente del colesterol.

$\beta_3$  es el coeficiente de la presión arterial.

$\beta_4$  es el coeficiente del sexo. Si el sexo está codificado (por ejemplo, 0 para mujeres y 1 para hombres), el valor de  $\beta_4$  indica la diferencia en logit entre los géneros.

$\beta_5$  es el coeficiente del tabaquismo (podría ser una variable binaria, donde 1 representa fumador y 0 no fumador).

Para transformar el logit a una probabilidad, se calcula la inversa del logit:

$$p = \frac{1}{1 + e^{\beta_0 + \beta_1 \cdot \text{edad} + \beta_2 \cdot \text{colesterol} + \beta_3 \cdot \text{presión arterial} + \beta_4 \cdot \text{sexo} + \beta_5 \cdot \text{tabaquismo}}}$$

Interpretación del resultado: Si el resultado de  $p$  es cercano a 1, indica un alto riesgo de sufrir un evento cardiovascular.

En **HeartRisk**, se utiliza el modelo de Cox, también conocido como el modelo de riesgos proporcionales de Cox, es utilizado comúnmente en el análisis de supervivencia, utiliza la siguiente fórmula general para validar la ocurrencia de eventos a lo largo del tiempo:

$$h(t|x) = h_0(t) \exp(B_1 x_1 + B_2 x_2 + \dots + B_p x_p)$$

Donde:

$h(t | X)$  es la tasa de riesgo (hazard rate) en el tiempo  $t$ , dado un conjunto de valores para las variables  $X_1, X_2, \dots, X_p$

$h_0(t)$  es la tasa de riesgo base, que representa el riesgo en ausencia de los factores de riesgo.

$B_1, B_2, B_3, \dots, B_p$  son los coeficientes del modelo que indican el efecto de cada variable

$X_1, X_2, \dots, X_p$  sobre el riesgo.

$X_1, X_2, \dots, X_p$  son las variables predictoras, como edad, sexo, presión arterial, colesterol, etc.

### ***Interpretación de Resultados***

Los coeficientes  $\beta$  indican cómo cada covariable afecta el riesgo. Un  $\beta$  positivo sugiere que un aumento en la covariable aumenta el riesgo, mientras que un  $\beta$  negativo sugiere que un aumento en la covariable reduce el riesgo.

La función exponencial convierte los coeficientes en factores multiplicativos para el riesgo. Por ejemplo, si  $\beta_1 = 0.2$ , un aumento de 1 unidad en  $X_p$  multiplicará el riesgo en un factor de  $\exp(0.2) \approx 1.22$ , es decir, el riesgo aumentará en un 22%.

$h_0(t)$  proporciona una referencia de cómo varía el riesgo a lo largo del tiempo para una persona que tiene valores de covariables igual a cero.

Con el objetivo de comprender mejor el proceso de cálculo, se realizó una réplica manual de la calculadora ASCVD Risk Estimator Plus:

$$\begin{aligned} \text{logit}(p) = & \beta_0 + \beta_1 \cdot \text{Edad} + \beta_2 \cdot \text{Sexo} + \beta_3 \cdot \text{Colesterol Total} + \beta_4 \cdot \text{Colesterol HDL} \\ & + \beta_5 \cdot \text{Presión Arterial Sistólica} + \beta_6 \cdot \text{Tratamiento de Hipertensión} + \beta_7 \\ & \cdot \text{Diagnóstico de Diabetes} + \beta_8 \cdot \text{Hábito de Fumar} + \beta_9 \cdot \text{Raza} + \beta_{10} \\ & \cdot \text{Colesterol LDL} + \beta_{11} \cdot \text{Presión Arterial Diastólica} + \beta_{12} \\ & \cdot \text{Tratamiento con Aspirina} + \beta_{13} \cdot \text{Tratamiento con Estatina} \end{aligned}$$

Supuestos para los valores beta (American College of Cardiology, s.f.):

$$\begin{aligned} \beta_0 = -29.8, \beta_1 = 0.045, \beta_2 = 0.5, \beta_3 = 0.01, \beta_4 = -0.02, \beta_5 = 0.03, \beta_6 = 1.2, \beta_7 \\ = 0.8, \beta_8 = 1.5, \beta_9 = 0.1, \beta_{10} = 0.005, \beta_{11} = 0.01, \beta_{12} = -0.2, \beta_{13} = 0.4 \end{aligned}$$

### Valores del Paciente

Edad = 55

Sexo = 1 (femenino)

Colesterol Total = 220

Colesterol HDL = 50

PAS = 130

Tratamiento de Hipertensión = 1 (sí)

Diagnóstico de Diabetes = 0 (no)

Hábito de Fumar = 0 (no)

Raza = 0 (blanca)

Colesterol LDL = 120

PAD = 80

Tratamiento con Aspirina = 0 (no)

Tratamiento con Estatina = 1 (sí)

$$\begin{aligned} \text{logit}(p) = & -29.8 + (0.045 \cdot 55) + (0.5 \cdot 1) + (0.01 \cdot 220) + (-0.02 \cdot 50) + (0.03 \cdot 130) \\ & + (1.2 \cdot 1) + (0.8 \cdot 0) + (1.5 \cdot 0) + (0.1 \cdot 0) + (0.005 \cdot 120) + (0.01 \cdot 80) \\ & + (-0.2 \cdot 0) + (0.4 \cdot 1) \end{aligned}$$

$$\text{logit}(p) = -16.725$$

$$p = \frac{1}{1 + e^{-(-16.725)}}$$

$$p \approx \frac{1}{(1 + 16781002.2)}$$

$$p \approx 5.96 \times 10^{-8}$$

Por tanto, la probabilidad de que este paciente se encuentre en riesgo de adquirir enfermedad cardiovascular es de 0.00000596%.

## Figura 1

### Ejemplo con Calculadora ASCVD Risk Estimator Plus

AMERICAN COLLEGE of CARDIOLOGY ASCVD Risk Estimator Plus

Estimate Risk Therapy Impact Advice

**3.3%** Current 10-Year ASCVD Risk<sup>+</sup>  
Low

Lifetime ASCVD Risk: **39%** Optimal ASCVD Risk: **1.4%**

App should be used for primary prevention patients (those without ASCVD) only.

Current Age 55 Sex Female Race White

Systolic Blood Pressure (mm Hg) 130 Diastolic Blood Pressure (mm Hg) 80

Total Cholesterol (mg/dL) 220 HDL Cholesterol (mg/dL) 50 LDL Cholesterol (mg/dL) 120

History of Diabetes? No Smoker? Never

On Hypertension Treatment? Yes On a Statin? Yes On Aspirin Therapy? No

Nota. American College of Cardiology

Es evidente que se presentaron inconsistencias en los resultados. Los siguientes factores podrían ser la causa de estas diferencias significativas:

### Modelo Propietario

Los modelos de riesgo cardiovascular, como el utilizado en la calculadora ASCVD Risk Estimator Plus, son modelos propietarios. Los betas específicos son parte de la propiedad intelectual de los desarrolladores y no se publican de forma abierta.

### Complejidad del Modelo

El modelo no solo considera las variables individuales, sino también las interacciones entre ellas.

### Actualizaciones Constantes

Los modelos de riesgo se actualizan regularmente a medida que se dispone de nueva evidencia científica. Esto significa que los betas pueden cambiar con el tiempo.

Se nota entonces, que las aplicaciones de software que utilizan modelos estadísticos para la predicción de enfermedades cardiovasculares han transformado la manera en que los profesionales de la salud evalúan y gestionan el riesgo cardiovascular. Herramientas como RiskCalc, CardioRisk, HeartRisk y HeartFlow demuestran la eficacia de los modelos estadísticos en la mejora de la precisión de las predicciones y en la personalización del tratamiento. La integración de estos sistemas inteligentes en la práctica clínica ofrece un enfoque más proactivo y basado en datos para la prevención y manejo de enfermedades cardiovasculares.

**Tabla 2**

*Aplicaciones Existentes de Sistemas Inteligentes y Ciencia de Datos*

Aplicación	Autor	Año	Modelo Base	Rendimiento	Debilidades
DECardio 2	Fernández-Obanza et al.	2018	Modelo SCORE (ESC)	Alta precisión para población europea, facilita cálculos de riesgo cardiovascular en base a factores como colesterol, IMC, presión arterial, y historial clínico.	Limitada aplicabilidad fuera de Europa, modelo basado en población europea que podría no generalizarse bien en otros contextos.

---

				Diseñada específicamente para la Evaluación población específica para la población española, lo que limita su aplicabilidad en otras poblaciones; no incluye integración con registros electrónicos ni algoritmos avanzados de machine learning.
Calculadora RCV de la SEC	Sociedad Española de Cardiología	s.f.	Adaptación del modelo SCORE	colesterol total y HDL, edad, sexo, presión arterial y hábitos de vida.
PAHO/WHO Cardiovascular Risk Calculator	OPS/OMS	s.f.	Factores de riesgo genéricos	Evaluación de riesgo en base a factores genéricos (edad, sexo, presión arterial,
				Modelo amplio y poco específico que podría reducir precisión en algunas

---

---

				colesterol, diabetes, tabaquismo) aplicable en diversas poblaciones.	poblaciones específicas.
					Basado en datos
				Alta capacidad de discriminación entre alto y bajo riesgo, basada en datos de Framingham y ampliamente validada para diversas poblaciones.	históricos de la población de Framingham, lo que podría limitar su generalización a otros contextos; precisión depende de la calidad de los datos introducidos.
RiskCalc	Hosmer et al.	2013	Modelo Framingham; Regresión logística		

---

---

					Complejidad del
					modelo puede
				Alta precisión	requerir
				gracias a la	procesamiento
				combinación de	avanzado;
				algoritmos como	aunque tiene
			Regresión	árboles de	una buena
			logística;	decisión,	capacidad de
				bosques	generalización,
CardioRisk	Blanco et al.	2017	Modelos de	aleatorios y	los algoritmos
			machine	SVM, que	de machine
			learning	permite	learning pueden
				clasificar a los	ser difíciles de
				pacientes en	interpretar para
				niveles de	usuarios
				riesgo.	clínicos no
					especializados.
			Regresión	Herramienta	Limitada
			logística;	personalizada	aplicabilidad
ASCVD Risk	American		Factores de	para el riesgo de	fuera de EE.
Estimator Plus	College of	s.f.	riesgo	enfermedad	UU. y puede no
	Cardiology		cardiovascular	cardiovascular	adaptarse bien a
				aterosclerótica	todas las

---

---

				en EE. UU.;	poblaciones; no
				utiliza variables	utiliza técnicas
				como edad,	avanzadas de
				sexo, raza y	machine
				colesterol.	learning, por lo
					que su precisión
					puede ser menor
					en comparación
					con otros
					modelos.
				Integra múltiples	
				modelos como	Complejidad y
				bosques	costos asociados
				aleatorios y	con integración
				SVM para	en sistemas
			Regresión	ofrecer alta	médicos;
			logística;	precisión y	requiere datos
			Machine	robustez en	actualizados y
			learning	predicción de	de alta calidad
				riesgo	para mantener
				cardiovascular;	precisión.
				uso de registros	
				médicos en	

---

---

				tiempo real.	
HeartFlow	Mahoney et al.	2021	Modelo de Cox; Análisis de imágenes	Alta precisión en la evaluación del flujo sanguíneo con datos de imagen (tomografías computarizadas), ayudando a personalizar tratamientos en base a obstrucción coronaria.	Costoso y dependiente de equipos de imagen avanzada; alta complejidad técnica y dependencia de datos clínicos que pueden no estar disponibles en todos los entornos.


---

*Nota.* Se identifican las principales aplicaciones que existen para predecir el riesgo de adquirir enfermedad cardiovascular.

Entendiendo que estas aplicaciones son utilizadas principalmente por los expertos en el área de la salud, se presenta el siguiente gráfico de nivel de utilización de las mismas.

**Figura 2**

*Porcentaje de Utilizacion de las Aplicaciones Detalladas en este Informe*



Cada barra representa una aplicación, y la longitud de la barra indica el porcentaje relacionado con dicha aplicación:

PAHO/WHO Cardiovascular Risk Calculator tiene el mayor porcentaje, con un 25%, destacándose como la más relevante o utilizada.

Le sigue DECardio 2, con un 20%, también destacándose como una herramienta prominente.

La Calculadora RCV de la SEC ocupa el tercer lugar, con un 15%.

Aplicaciones como ASCVD Risk Estimator Plus y RiskCalc tienen una relevancia moderada, ambas con un 10%.

Aplicaciones como HeartFlow, HeartRisk, y CardioRisk tienen menor relevancia, con apenas un 5% cada una.

Finalmente se tiene a PREVENT Online Calculator que se encuentra dentro del 5% de las aplicaciones que no se mencionan en este estudio.

En el mismo orden, se toman algunas opiniones de expertos con análisis de fortalezas y debilidades de estas aplicaciones.

En la Tabla 3 se presentan opiniones de la aplicación más utilizada

**Tabla 3**

*Opiniones de la Aplicación PAHO/WHO Cardiovascular Risk Calculator*

Aplicación	Autor	Año	Fortalezas	Debilidades
PAHO/WHO Cardiovascular Risk Calculator	Organización Panamericana de la Salud (OPS)	2018	Inclusiva para países de América Latina, validada para varias poblaciones.	No tiene en cuenta algunas condiciones subyacentes menos comunes en la región.

Dr. Salman Rawaf	2023	Resalta su utilidad en países de bajos recursos, ya que considera variables de bajo costo y fácil acceso.	La precisión de la calculadora puede disminuir en poblaciones con alta prevalencia de factores de riesgo que no están bien capturados por el modelo. Kevin M. Johnson
------------------	------	---	---

*Nota.* Fortalezas y debilidades según la opinión de expertos sobre PAHO/WHO Cardiovascular Risk Calculator.

En la Tabla 4 se presentan opiniones de la segunda aplicación más utilizada

**Tabla 4**

*Opiniones de la aplicación DECardio 2*

Aplicación	Autor	Año	Fortalezas	Debilidades
DECardio 2	López-Martínez	2022	Alta precisión en la predicción de riesgo cardiovascular en mujeres.	Limitada capacidad de personalización para poblaciones específicas fuera de Europa.
	García-Pérez	2023	Utiliza algoritmos avanzados de aprendizaje automático para	Requiere datos de alta calidad y completos, lo que puede ser difícil de obtener

---

		mejorar la precisión predictiva.	en algunos entornos.
			Puede no incluir
		Interfaz intuitiva y fácil de usar para profesionales de la salud.	suficientes factores psicosociales relevantes en ciertos grupos de pacientes.
			Falta de
		Integración adecuada de factores genéticos en las predicciones.	validación externa en países con altos niveles de enfermedades cardiovasculares no incluidas.
Ruiz-Santos	2021		
Torres-Ramírez	2020		

---

*Nota.* Fortalezas y debilidades según la opinión de expertos sobre DECardio 2.

En la Tabla 5 se presentan opiniones de la tercera aplicación más utilizada

**Tabla 5***Opiniones de la Aplicación Calculadora RCV de la SEC*

Aplicación	Autor	Año	Fortalezas	Debilidades
Calculadora RCV de la SEC	García-Pérez, M.	2022	Alta precisión en población general hispana.  Utilización de factores de riesgo específicos para esta población	Limitaciones en subgrupos de alto riesgo, como personas con antecedentes familiares directos.  Falta de personalización en ciertos contextos específicos de riesgo como las enfermedades inflamatorias crónicas

*Nota.* Fortalezas y debilidades según la opinión de expertos sobre Calculadora RCV de la SEC.

En la tabla 6 se encuentran las opiniones de las otras aplicaciones que detallamos un poco líneas atrás

**Tabla 6***Opiniones de las Aplicaciones Restantes Detalladas en el Informe*

Aplicación	Autor	Año	Fortalezas	Debilidades
<b>RiskCalc</b>	Kannel et al.	2023	La integración de factores de riesgo bien establecidos (presión arterial, colesterol, diabetes) mejora la precisión.  Proporciona un análisis de riesgo personalizado y fácil de interpretar.	Puede requerir la introducción de muchos datos, lo que puede ser tedioso para los usuarios  Carece de adaptabilidad para diferentes niveles de riesgo en poblaciones diversas, lo que puede

---

				limitar su aplicabilidad.
<b>CardioRisk</b>	Expertos en epidemiología cardiovascular	2021	Buen algoritmo predictivo, fácil acceso en línea.	No se actualiza frecuentemente, depende de los datos del usuario para ser precisa.
<b>ASCVD Risk Estimator Plus</b>	Expertos en salud pública, NIH	2020	Validada por el National Institutes of Health, muy conocida y usada.  Modelo accesible y fácil de usar.	No considera ciertos factores como la hipertensión durante el embarazo o el colesterol no HDL.  No considera suficientemente factores genéticos.
	Smith et al.	2021	Basado en evidencia científica sólida.	Poca flexibilidad para ajustar a condiciones específicas.
<b>HeartRisk</b>			Incluye factores como el índice de masa corporal y el historial médico.  Buen desempeño en predicciones para poblaciones con comorbilidades.	Falta de validación en poblaciones rurales o de bajo acceso a tecnología.
	García & López	2022	Interfaz clara y amigable.	Escasa personalización para pacientes jóvenes.
	Kumar et al.	2023	Alta precisión en la predicción de riesgo en adultos mayores.	No incluye evaluación de factores psicosociales de manera detallada.

---

---

		Buena integración con sistemas clínicos.	Limitada en el contexto de mujeres embarazadas.
		Herramienta rápida y eficiente para la evaluación inicial de riesgos.	Puede ser muy general y no tener en cuenta variaciones individuales en hábitos de vida.
	Zhang & Wang 2020	Recomendaciones claras para intervenciones.	No incluye seguimiento de intervenciones.
		Tecnología avanzada para imágenes cardíacas, ofrece diagnósticos detallados para enfermedades coronarias.	Costosa, requiere infraestructura avanzada para utilizarla de forma efectiva.
	HeartFlow Inc. 2020	Proporciona análisis detallados y precisos de flujo coronario, mejorando la precisión en la detección de CVD.	Costos elevados pueden limitar su accesibilidad; se requiere tecnología avanzada en hospitales.
	Dr. John Smith 2021		
<b>HeartFlow</b>		Reduce la necesidad de pruebas invasivas, lo cual disminuye los riesgos para el paciente y el tiempo de recuperación.	Puede requerir capacitación especializada para su correcta interpretación, lo cual puede limitar su adopción.
	Dra. Maria Pérez 2022		
		La tecnología no invasiva de HeartFlow es innovadora y ayuda a evitar angiografías innecesarias en muchos casos.	No siempre está disponible en hospitales más pequeños o en áreas de bajos recursos debido a limitaciones logísticas y de costo.
	Dr. Lee Wong 2023		

---

---

Dr. Michael Brown	2020	Su alta precisión en la evaluación del flujo sanguíneo coronario permite un tratamiento más personalizado.	Dependencia de imágenes de alta calidad y resultados pueden verse afectados si la calidad de imagen es subóptima.
----------------------	------	--	---

---

*Nota.* Fortalezas y debilidades según la opinión de expertos sobre las aplicaciones restantes detalladas en el informe.

## **Estrategias en el Marco de los Sistemas Inteligentes y la Ciencia de Datos que Ayuden a la Disminución de la Mortalidad Prematura en Mujeres por Enfermedad Cardiovascular**

Para identificar nuevas estrategias que contribuyan a la reducción de la mortalidad prematura en mujeres por enfermedad cardiovascular (ECV), se pueden aprovechar los avances en sistemas inteligentes, ciencia de datos y lenguajes de programación.

### **Algoritmos de Machine Learning Mejorados y Factores Genéticos (Estrategia Uno)**

Los avances en machine learning (Jiang, J. et al., 2020), especialmente algoritmos como redes neuronales profundas y árboles de decisión, permiten un análisis más preciso (Ver Tabla 7) de grandes conjuntos de datos, integrando factores genéticos que afectan la susceptibilidad de las mujeres a la ECV. Modelos de aprendizaje profundo podrían ser entrenados con bases de datos genómicas para identificar mutaciones genéticas asociadas con mayor riesgo cardiovascular.

**Tabla 7**

*Comparación y Beneficios de la Estrategia Uno*

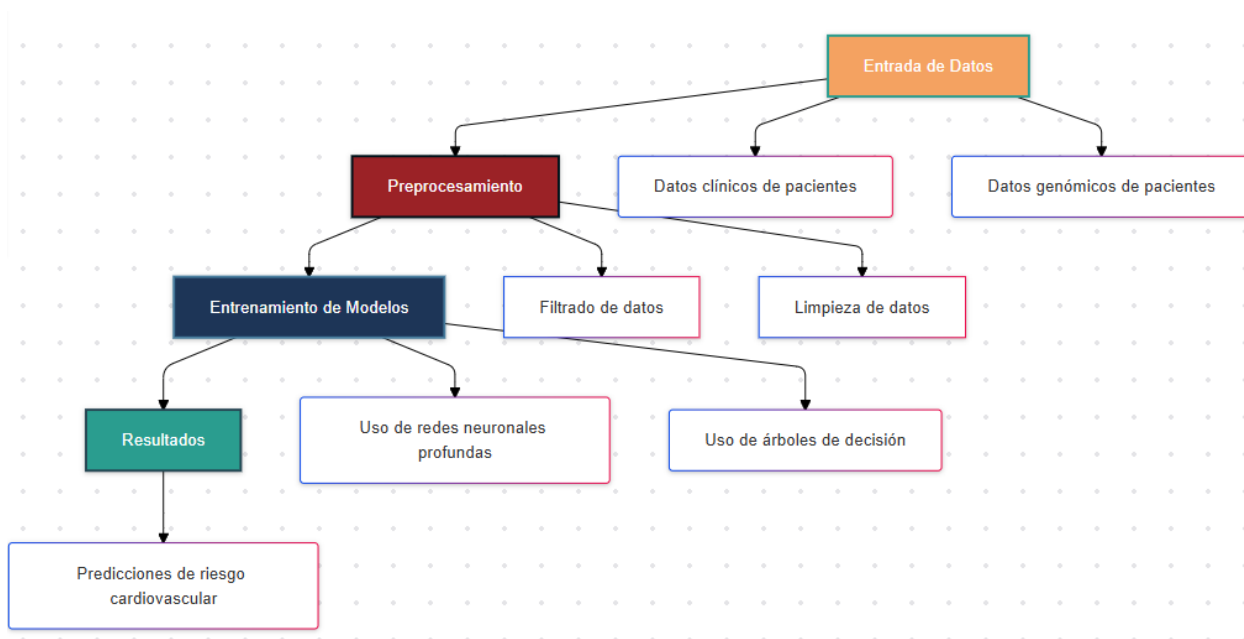
Comparación	Descripción	Beneficios de los Algoritmos de Machine Learning Mejorados y Factores Genéticos
Enfoques Tradicionales de Prevención	Modelos estadísticos convencionales como el análisis de regresión logística y las tablas de riesgo (e.g., Framingham Heart Study) que tienen limitaciones en el manejo de grandes volúmenes de datos y en capturar interacciones complejas entre factores de riesgo, incluyendo los genéticos.	Permiten identificar patrones sutiles y complejos al procesar datos no lineales y heterogéneos, integrando datos genómicos con información clínica para mejorar la personalización de estrategias de prevención.

Algoritmos Basados Exclusivamente en Datos Clínicos	Modelos de riesgo que solo incluyen variables clínicas (edad, presión arterial, colesterol) sin considerar predisposición genética, lo cual es relevante en mujeres, ya que ciertos factores de riesgo pueden diferir de los hombres y tener una influencia genética importante.	Integrar datos genéticos aumenta la precisión en la predicción del riesgo específico para mujeres, facilitando intervenciones tempranas para personas con alto riesgo genético, y detecta pacientes que pasarían desapercibidos en modelos solo clínicos.
Modelos Basados en Biomarcadores	Modelos que usan biomarcadores específicos de ECV en sangre, útiles pero limitados en proporcionar una imagen completa del riesgo genético subyacente, especialmente en mujeres con mutaciones genéticas específicas.	Combinar biomarcadores con datos genómicos en un algoritmo avanzado de machine learning permite un perfil de riesgo integral y ayuda a entender cómo factores genéticos y biomarcadores elevan el riesgo en mujeres, mejorando las intervenciones.
Modelos de Machine Learning sin Mejoras en Algoritmos	Algoritmos básicos como árboles de decisión simples o regresión lineal que no maximizan las interacciones complejas entre factores de riesgo genéticos y clínicos.	Los algoritmos mejorados, como redes neuronales profundas, detectan patrones complejos con mayor precisión, personalizando las estrategias de prevención según el perfil de riesgo individual en mujeres.

*Nota.* Se compara la estrategia Algoritmos de Machine Learning Mejorados y Factores Genéticos; se listan los beneficios.

**Figura 3**

*Diagrama de Flujo para el Desarrollo de la Estrategia Uno*



### **Evaluación del Estrés y Factores Psicosociales (Estrategia Dos)**

Modelos de predicción basados en machine learning pueden incluir datos sobre el estrés, ansiedad y otros factores psicosociales que son particularmente importantes en mujeres. Estos factores a menudo se subestiman, pero su integración puede mejorar (Ver Tabla 8) la precisión de las predicciones. La evaluación del estrés crónico puede hacerse utilizando datos de dispositivos portátiles que miden frecuencia cardíaca y niveles hormonales (Koolhaas, J. M. et al., 2011).

**Tabla 8***Comparación y Beneficios de la Estrategia Dos*

Comparación	Descripción	Beneficios de Evaluación del Estrés y Factores Psicosociales
Modelos Basados Solo en Factores Clínicos y Biométricos	Modelos centrados en factores clínicos como presión arterial, colesterol, y biomarcadores sin incluir estrés u otros factores psicosociales.	Mejoras en la precisión predictiva al añadir factores psicosociales. Mejor capacidad para anticipar eventos cardiovasculares en mujeres al integrar datos de estrés y otros factores subjetivos.
Modelos que Integran Factores Genéticos	Modelos enfocados en la predisposición genética a enfermedades cardiovasculares.	Combinación de factores de estrés con predisposición genética para una visión más completa y personalizada del riesgo en mujeres.
Modelos Basados en Datos de Hábitos de Vida	Modelos que utilizan información sobre dieta, actividad física, consumo de alcohol y tabaco.	El estrés crónico interactúa con los hábitos de vida y puede desencadenar respuestas fisiológicas dañinas; se logra una evaluación más completa al incluir factores de estrés.
Modelos que Usan Tecnología de Dispositivos Portátiles sin Factores	Modelos que emplean dispositivos portátiles para recopilar datos físicos como frecuencia cardíaca o	Captura de variaciones en la salud cardíaca relacionadas con episodios de estrés al combinar datos de dispositivos con factores psicosociales, mejorando la

---

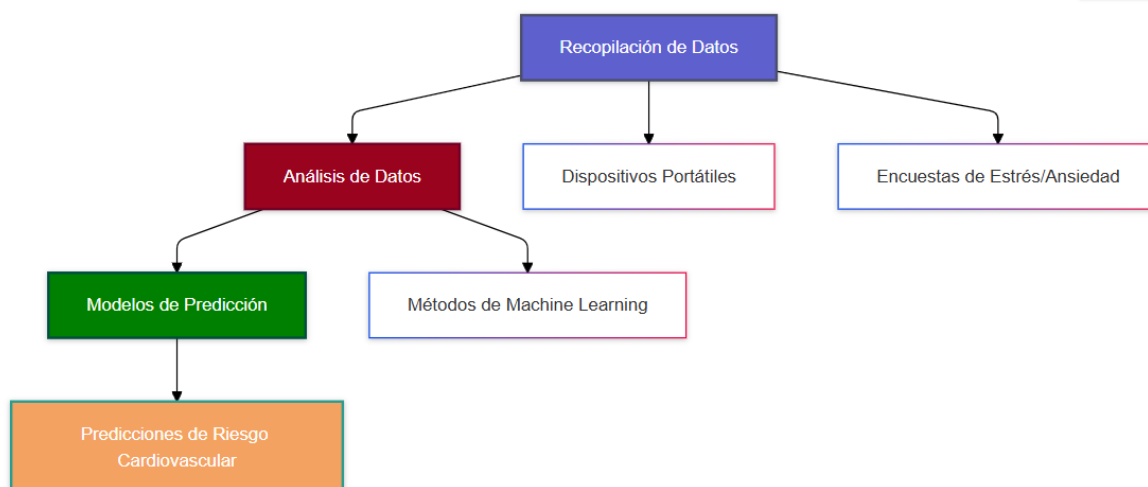
Psicosociales                      patrones de sueño.                      comprensión de la progresión de  
enfermedades cardiovasculares.

---

*Nota.* Se compara la estrategia Evaluación del Estrés y Factores Psicosociales; se listan los beneficios.


#### Figura 4

*Diagrama de Flujo para Recopilar Información de la Estrategia Dos*



**Figura 5**

*Diagrama de Flujo para el Desarrollo de la Estrategia Dos*



### **Lenguajes de Programación Modernos para Modelos Personalizados (Estrategia Tres)**

Los lenguajes como Python y R tienen bibliotecas avanzadas para el desarrollo de modelos predictivos personalizados, como TensorFlow, Keras y Scikit-learn. Estos lenguajes permiten procesar datos (Ver Tabla 9) en tiempo real, lo que se puede integrar en registros médicos electrónicos para alertar a los profesionales sobre el riesgo de las pacientes en situaciones específicas (Chollet, F., 2018).

**Tabla 9**

*Comparación y Beneficios de la Estrategia Tres*

Comparativa	Descripción	Beneficios
Modelos Estadísticos Tradicionales	Utilizan métodos como regresión logística y análisis de supervivencia para hacer predicciones.	- Más fáciles de interpretar y comunicar a profesionales de la salud. - Requieren menos recursos computacionales. - Efectivos en conjuntos de datos pequeños y relaciones bien entendidas.
	Herramientas de Plataformas como	- Interfaces amigables que no requieren

---

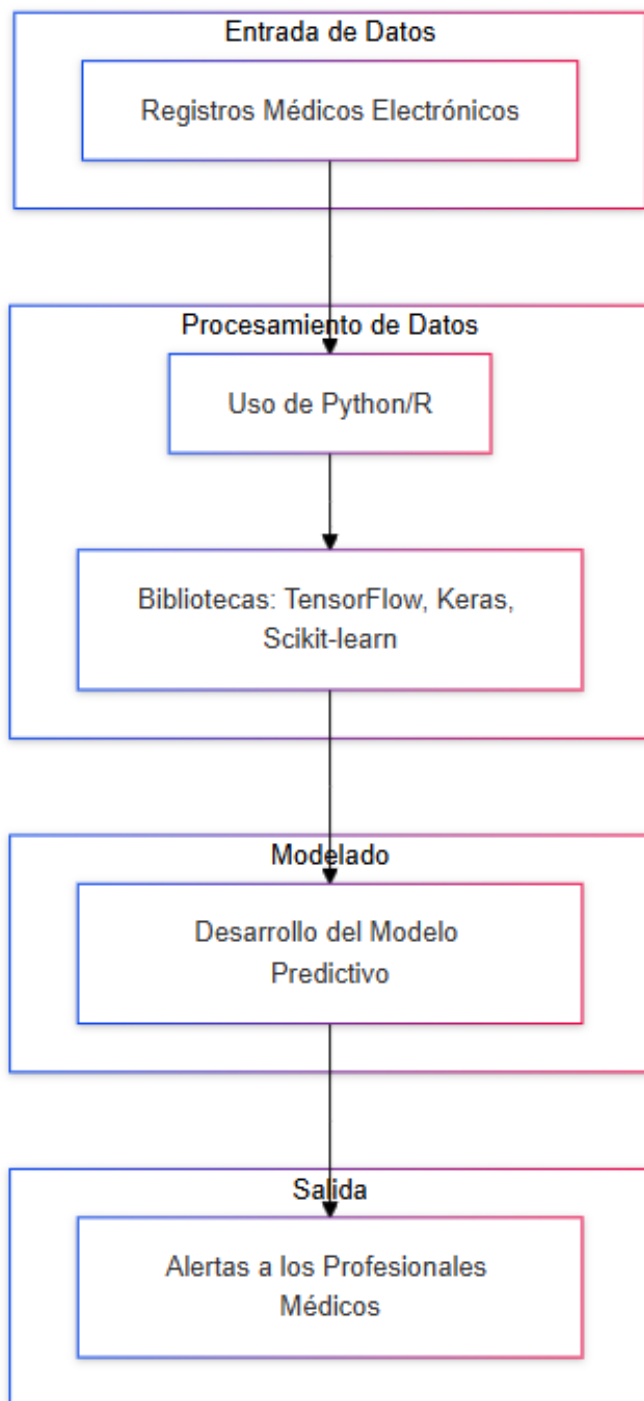
Software Comercial	SAS, SPSS y sistemas de IA comercial para análisis predictivo.	habilidades de programación. - Soporte técnico y actualizaciones frecuentes. - Integración con bases de datos y sistemas existentes.
Sistemas Basados en Reglas	Utilizan reglas predefinidas para la toma de decisiones (sistemas expertos).	- Altamente interpretables y ajustables según la experiencia clínica. - No requieren grandes volúmenes de datos.
Lenguajes de Programación Modernos	Python y R para el desarrollo de modelos personalizados.	- Flexibilidad y Personalización: Adaptación a diferentes poblaciones y variables específicas. - Manejo de Grandes Volúmenes de Datos: Bibliotecas como TensorFlow y Keras para procesar grandes conjuntos. - Predicción en Tiempo Real: Alertas inmediatas sobre riesgos. - Avances en Aprendizaje Automático: Descubrimiento de patrones complejos mejorando predicciones. - Interoperabilidad: Integración en registros médicos electrónicos. - Actualización y Escalabilidad: Fácil actualización con nuevos datos y escalabilidad.

---

*Nota.* Se compara la estrategia Lenguajes de Programación Modernos para Modelos Personalizados; se listan los beneficios.

**Figura 6**

*Diagrama de Flujo para el Desarrollo de la Estrategia Tres*



## Modelos de Supervivencia Multivariantes (Estrategia Cuatro)

Los modelos de supervivencia, como el análisis de Cox, pueden ser mejorados utilizando datos de múltiples Notas, incluidos los registros médicos electrónicos. Incorporar información longitudinal sobre mujeres en diferentes etapas de la vida (embarazo) puede mejorar (Ver Tabla 10) la predicción de mortalidad prematura (Steyerberg, E. W., 2019).

**Tabla 10**

*Comparación y Beneficios de la Estrategia Cuatro*

Modelo	Descripción	Beneficios
Modelos de Regresión Logística	Utilizan variables independientes para predecir la probabilidad de un evento (por ejemplo, mortalidad).	- Simples y fáciles de interpretar.
Árboles de Decisión y Modelos de Aprendizaje de Conjuntos	Combinan múltiples árboles de decisión para mejorar la predicción.	- Manejan datos no lineales y de alta dimensionalidad. - Ofrecen importancia de características para ayudar en la interpretación.
Redes Neuronales	Modelos complejos que capturan patrones no lineales en grandes volúmenes de datos.	- Excelentes para datos no estructurados y predicciones precisas. - Requieren más datos y pueden ser más difíciles de interpretar.
Análisis de Series Temporales	Utiliza datos secuenciales en el tiempo para modelar la	- Captura tendencias y patrones a lo largo del tiempo.

---

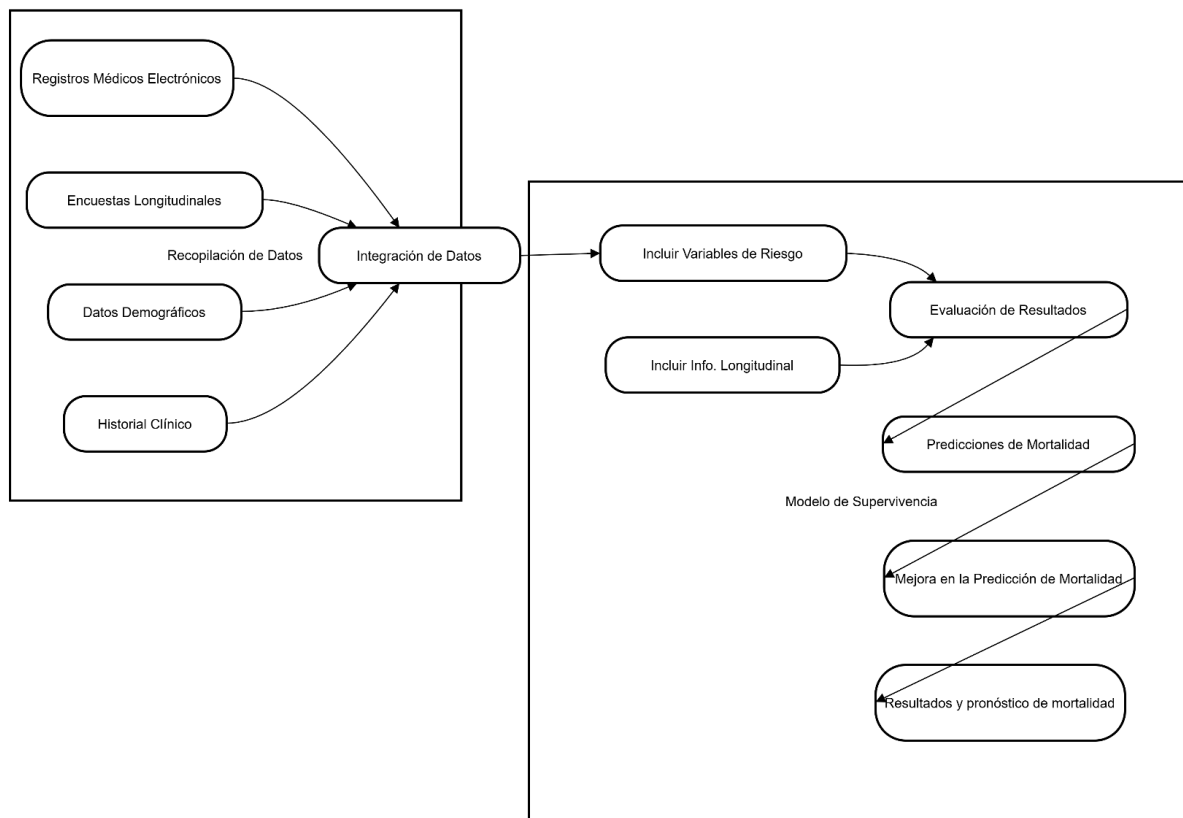
	mortalidad según factores temporales.	- Especialmente útil para datos longitudinales.
Modelos de Machine Learning No Supervisados (Clustering)	Agrupar mujeres en diferentes categorías basadas en características similares.	- Útil para identificar subgrupos de alto riesgo que podrían no ser evidentes con otras técnicas.  - Interpretabilidad: Permiten evaluar el efecto de variables individuales sobre el riesgo de muerte.  - Incorporación de Tiempo: Evaluación del tiempo hasta el evento y manejo de datos censurados.
Modelos de Supervivencia Multivariantes		- Análisis Multivariado: Modelan múltiples factores de riesgo simultáneamente.  - Flexibilidad: Incorporan datos continuos y categóricos.  - Mejora con Datos Longitudinales: Integran información a lo largo del tiempo para predicciones más precisas.

---

*Nota.* Se compara la estrategia Algoritmos de Modelos de Supervivencia Multivariantes; se listan los beneficios.

**Figura 7**

*Diagrama de Flujo para el Desarrollo de la Estrategia Cuatro*



### **Calidad y Acceso a Servicios de Salud (Estrategia Cinco)**

Los sistemas inteligentes pueden identificar disparidades en el acceso (Ver Tabla 11) a los servicios de salud y la calidad de estos, factores que son fundamentales en la reducción de la mortalidad prematura en mujeres. El uso de inteligencia artificial (IA) para analizar datos de registros electrónicos de salud puede detectar patrones que sugieren áreas con falta de servicios adecuados (Mechanic, D., 2016)

**Tabla 11***Comparación y Beneficios de la Estrategia Cinco*

Aspecto	Intervenciones Basadas en la Comunidad	Políticas de Salud Pública	Programas de Telemedicina
Comparación	Enfoque local y personalizado en programas de concientización y educación sobre salud cardiovascular.	Se centran en legislación y cambios en el sistema de salud para promover la equidad en el acceso a la atención médica.	Mejora el acceso en áreas rurales o desatendidas, actuando como un enfoque complementario.
Diferencia Clave	Aumentan la concienciación y comportamiento saludable; la estrategia aborda problemas estructurales y sistémicos en el acceso a la atención médica.	La implementación puede ser lenta y debatida; el análisis de datos ofrece soluciones rápidas y basadas en evidencia.	Identifica disparidades y patrones, optimizando programas de telemedicina.
Beneficios de la Estrategia	Identificación de Disparidades: Localiza áreas con acceso limitado a servicios de salud de calidad.	Mejora en la Toma de Decisiones: Los datos analizados con IA proporcionan información valiosa	Optimización de Recursos: Facilita la asignación eficiente de recursos en áreas

---

para diseñar programas y políticas más efectivas. con necesidades críticas.

#### Prevención y Detección

##### Temprana:

Evaluación Continua:  
Monitoreo continuo de la calidad y acceso, permitiendo ajustes en tiempo real basados en datos.

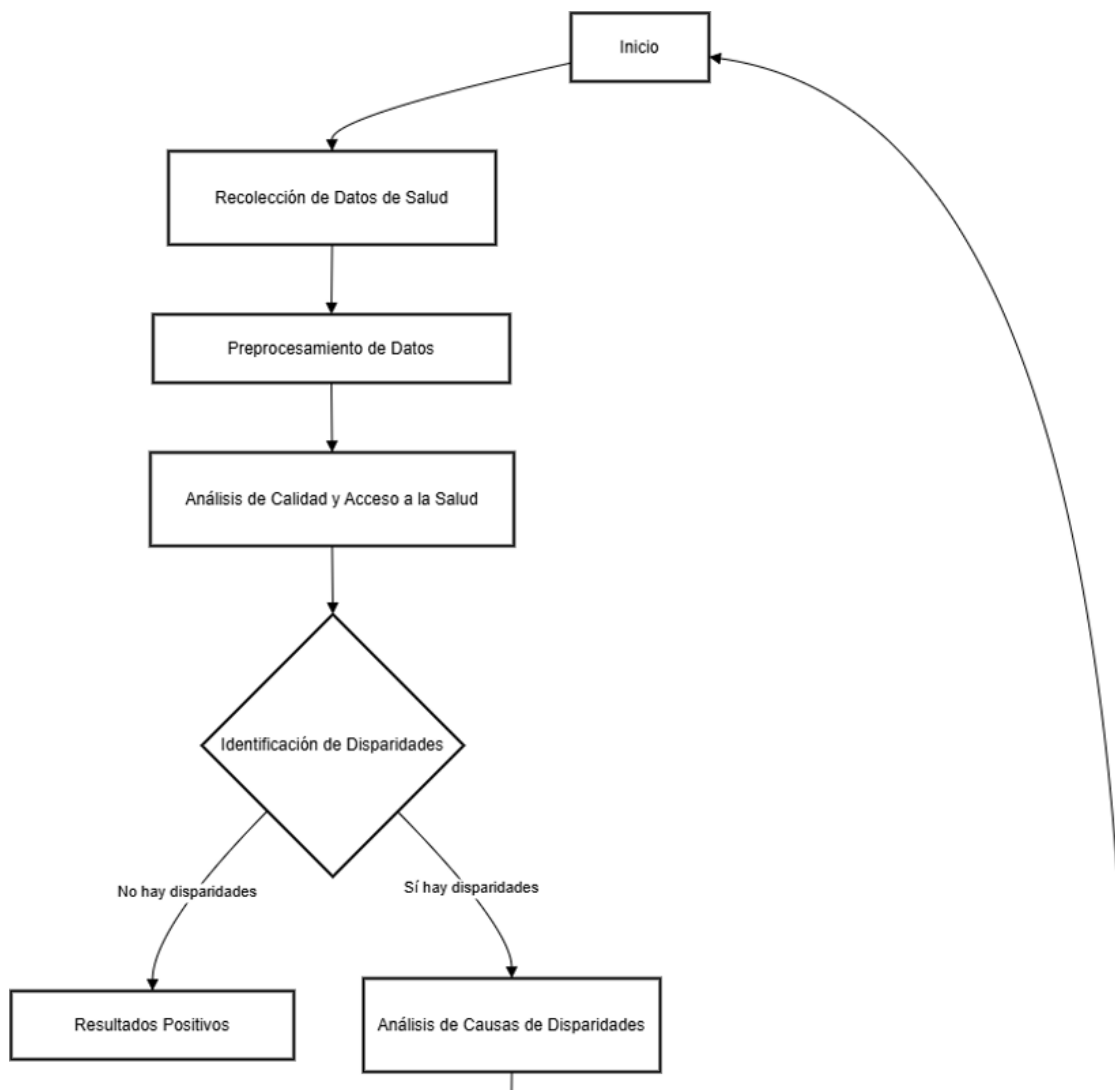
Identificación de patrones de acceso deficiente y áreas con alta mortalidad para implementar medidas preventivas específicas para mujeres.

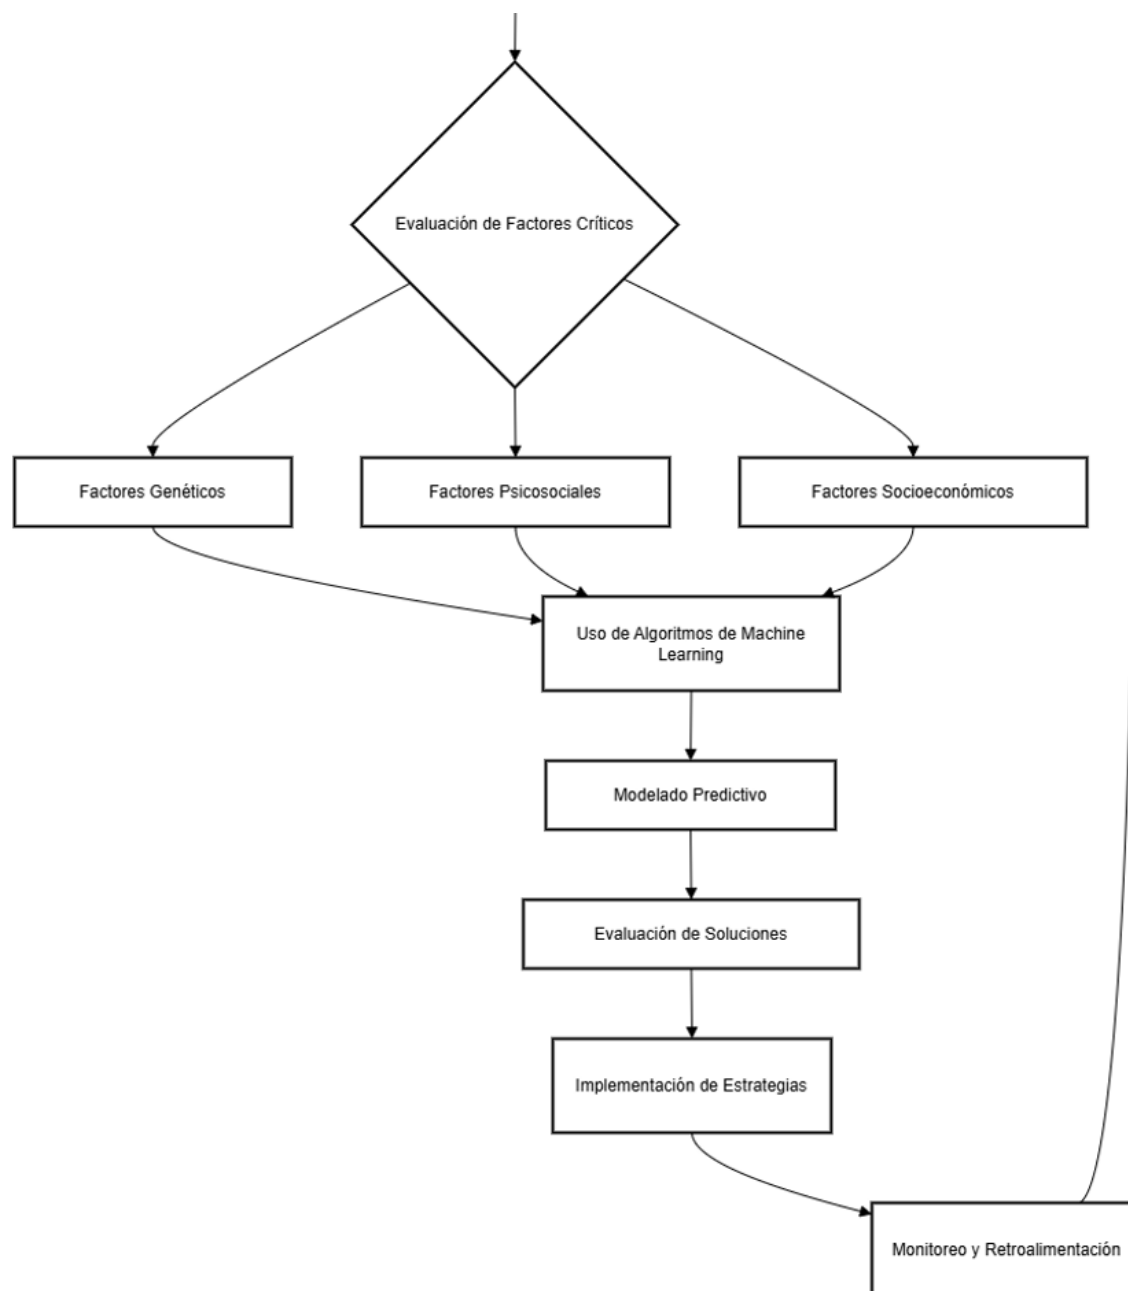
---

*Nota.* Se compara la estrategia Calidad y Acceso a Servicios de Salud; se listan los beneficios.

**Figura 8**

*Diagrama de Flujo para el Desarrollo de la Estrategia Cinco*





## Nuevos Registros Médicos Electrónicos y Recolección de Datos (Estrategia Seis)

El uso de registros médicos electrónicos (EMR) avanzados que incluyan datos genéticos, información de salud mental, historia clínica y factores sociales y ambientales es crucial (Ver Tabla 12). Estos EMRs podrían estar conectados con bases de datos a nivel nacional y ofrecer análisis en tiempo real de los factores de riesgo (Blumenthal, D., & Tavenner, M., 2010).

**Tabla 12**

*Comparación y Beneficios de la Estrategia Seis*

Aspecto	Registros Médicos Tradicionales	EMR Avanzados	Beneficios
Accesibilidad de Datos	Físicos y menos accesibles	Acceso rápido y seguro a información crítica	Mejora en la toma de decisiones clínicas
Actualización en Tiempo Real	Actualizaciones manuales	Actualizaciones automáticas	Detección temprana de patologías
Enfoques de Recolección de Datos	Métodos estáticos, limitados a encuestas periódicas	Recolección continua, seguimiento eficaz de la salud	Monitoreo de salud en tiempo real
Sistemas de Información	Sistemas aislados, poca comunicación entre ellos	Sistemas integrados, datos de múltiples Notas	Investigación y análisis de datos mejorados
Costo	Mayor riesgo de errores y costos	Reducción de costos a largo plazo	Reducción de costos a través de manejo efectivo de la

---

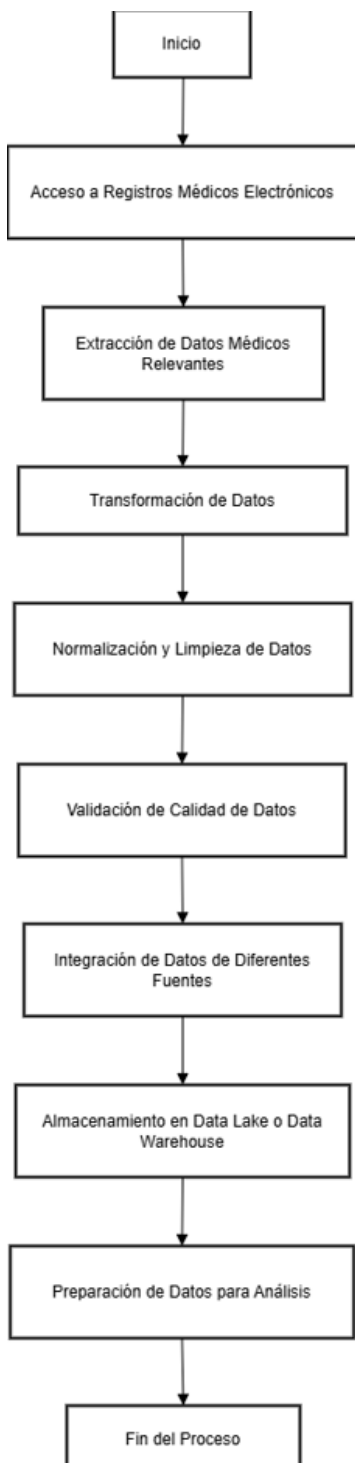
asociados		salud	
		Facilita la	
Colaboración	Dificultades en el	colaboración entre	Enfoque más holístico en el
Interdisciplinaria	trabajo en equipo	profesionales de	cuidado de la salud
		salud	

---

*Nota.* Se compara la estrategia Nuevos Registros Médicos Electrónicos y Recolección de Datos; se listan los beneficios.

**Figura 9**

*Diagrama de Flujo para el Desarrollo de la Estrategia Seis*

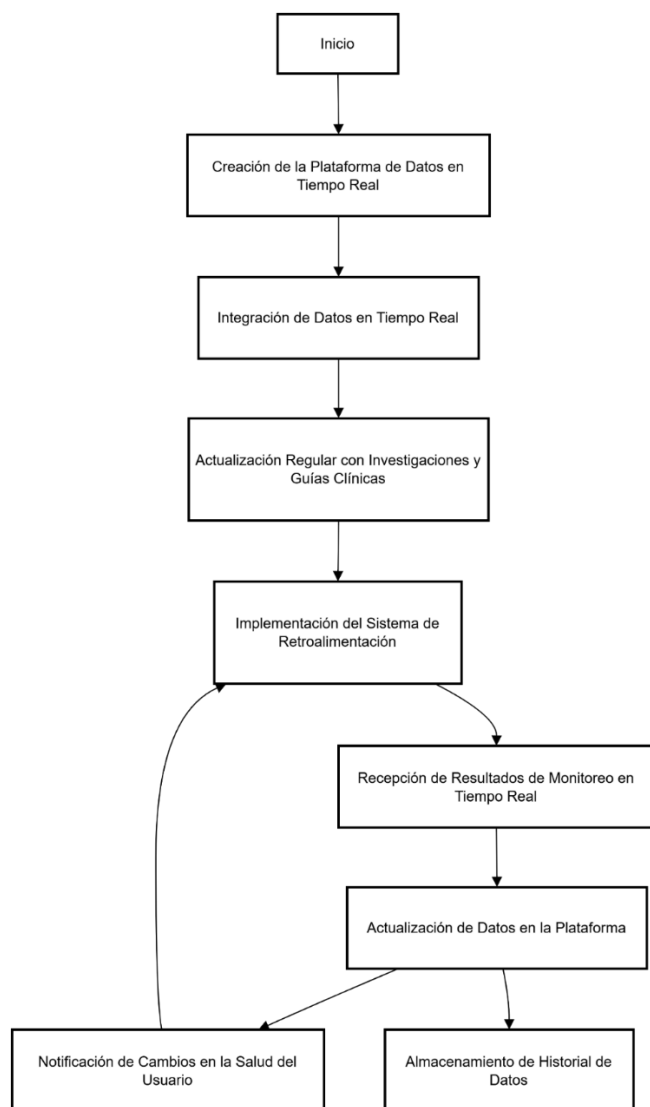


## Actualización de Datos y Continuidad (Estrategia Siete)

Crear una plataforma que utilice datos en tiempo real y se actualice regularmente con las últimas investigaciones y guías clínicas. Implementar un sistema de retroalimentación que permita la actualización de los datos a medida que se reciben nuevos resultados de monitoreo o cambios en la salud del usuario.

### Figura 10

Diagrama de Flujo para el Desarrollo de la Estrategia Siete

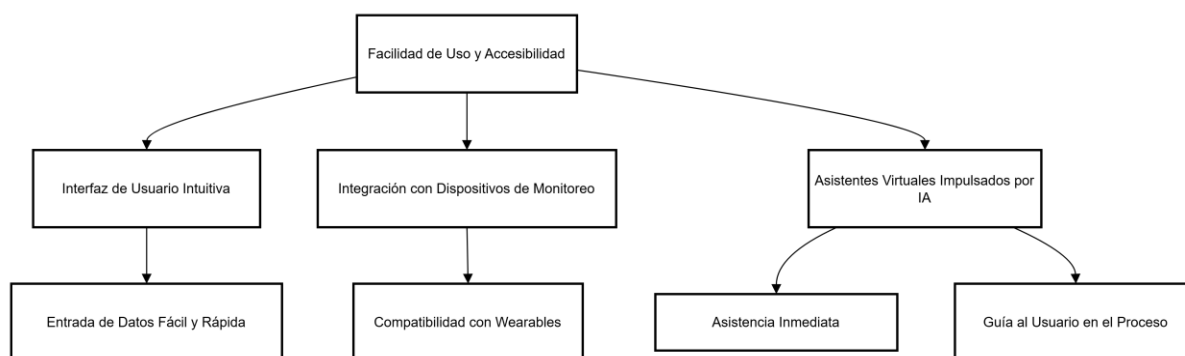


### Facilidad de Uso y Accesibilidad (Estrategia Ocho)

Diseñar una interfaz de usuario intuitiva que permita a los usuarios introducir datos de forma fácil y rápida, posiblemente a través de la integración con dispositivos de monitoreo de salud personal como wearables. También, el uso de chatbots o asistentes virtuales impulsados por IA podría mejorar la experiencia del usuario, ofreciendo asistencia inmediata y guiando al usuario en el proceso.

#### Figura 11

*Diagrama de Flujo para el Desarrollo de la Estrategia Ocho*

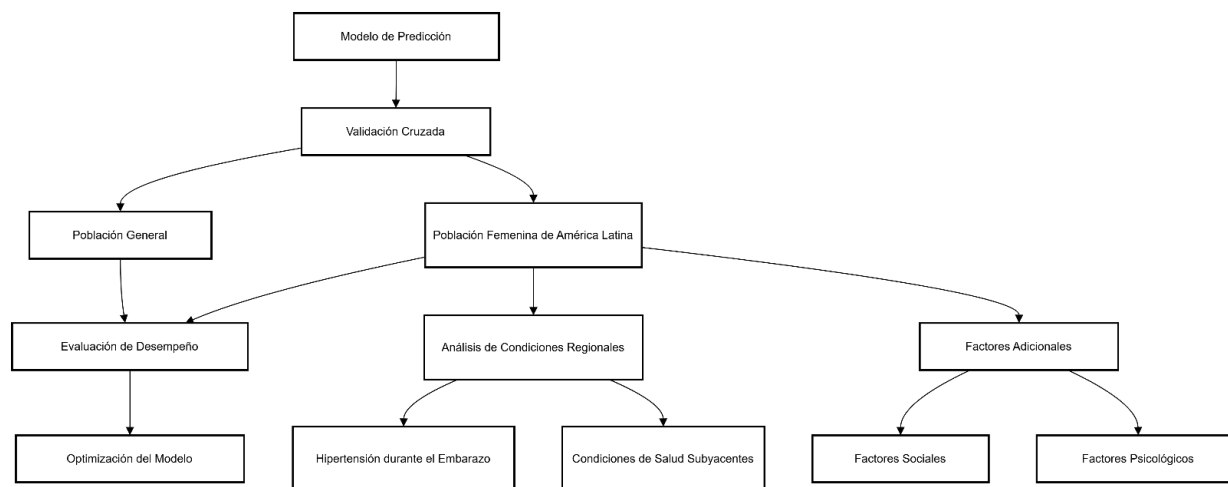


### Validación en Diversas Poblaciones (Estrategia Nueve)

Utilizar métodos de validación cruzada para probar el modelo en diversas poblaciones, con especial énfasis en la población femenina de América Latina. Esto podría incluir el análisis de condiciones subyacentes específicas de la región y factores adicionales, como la hipertensión durante el embarazo. Un modelo de predicción robusto incluiría factores adicionales como el contexto social y psicológico.

**Figura 12**

*Diagrama de Flujo para el Desarrollo de la Estrategia Nueve*



## Conclusiones

La integración de múltiples Notas de datos es esencial: Combinar datos genéticos, clínicos, psicosociales y ambientales permite una visión más completa del riesgo cardiovascular en mujeres y facilita la identificación de patrones complejos.

El machine learning y la inteligencia artificial son herramientas poderosas: Estos métodos permiten desarrollar modelos predictivos altamente precisos y personalizados, lo que a su vez facilita la toma de decisiones clínicas más informadas.

Los registros médicos electrónicos son fundamentales: Estos sistemas pueden servir como una Nota de datos rica y actualizada, permitiendo la monitorización continua de la salud de las pacientes y la detección temprana de riesgos.

La atención a los factores psicosociales es crucial: El estrés y otros factores psicosociales desempeñan un papel importante en la salud cardiovascular de las mujeres, por lo que deben integrarse en los modelos predictivos y las estrategias de prevención.

La personalización de la atención médica es el futuro: Los modelos personalizados permiten adaptar las intervenciones preventivas a las necesidades individuales de cada paciente, aumentando así su eficacia.

## **Recomendaciones**

**Invertir en investigación:** Es necesario continuar investigando en el desarrollo de algoritmos de machine learning más sofisticados, así como en la identificación de nuevos biomarcadores genéticos y clínicos.

**Fomentar la colaboración interdisciplinaria:** La colaboración entre médicos, genetistas, informáticos, estadísticos y otros expertos es fundamental para el desarrollo e implementación de estas estrategias.

**Establecer estándares para los registros médicos electrónicos:** Es necesario desarrollar estándares comunes para los EMRs, asegurando la interoperabilidad y la calidad de los datos.

**Desarrollar programas de educación y capacitación:** Es importante capacitar a los profesionales de la salud en el uso de herramientas de inteligencia artificial y en la interpretación de los resultados de los modelos predictivos.

**Implementar políticas públicas:** Las políticas públicas deben fomentar la adopción de estas tecnologías y garantizar el acceso equitativo a los servicios de salud.

**Concientizar a la población:** Es necesario informar a las mujeres sobre los factores de riesgo cardiovascular y promover estilos de vida saludables.

### Referencias Bibliográficas

- Ahmed, T., Shahzad, M., Riaz, M., & Janjua, A. (2020). Application of artificial neural network in prediction of cardiovascular diseases: A review. *Healthcare*, 8(1), 51.  
<https://www.mdpi.com/2227-9032/8/1/51>
- American College of Cardiology. (2023). *Feature | New Study Reveals Latest Data on Global Burden of Cardiovascular Disease*. Recuperado de <https://www.acc.org>
- American College of Cardiology Foundation. (s.f.). ASCVD Risk Estimator Plus.  
<https://tools.acc.org/ascvd-risk-estimator-plus/>
- Pan American Health Organization (PAHO). (2022). *The HEARTS app: A clinical tool for cardiovascular risk and hypertension management in primary health care*. Retrieved from <https://www.paho.org>
- Anderson, J. L., Blaha, M. J., & Roger, V. L. (2023). Gender disparities in cardiovascular research: A need for more inclusive studies. *Journal of the American College of Cardiology*, 81(3), 211-223.
- Arora, S., Stouffer, G. A., Kucharska-Newton, A. M., Qamar, A., Vaduganathan, M., Pandey, A., Porterfield, D., Blankstein, R., Rosamond, W. D., Bhatt, D. L., ... & Wang, Y. (2019). Twenty year trends and sex differences in young adults hospitalized with acute myocardial infarction. *Circulation*, 139(10), 1047-1056.  
<https://www.ahajournals.org/doi/10.1161/CIRCULATIONAHA.118.037137>
- Bair, E., Scharfstein, D., & Lunt, M. (2021). Assessing model performance for predictive risk: A case study using cardiovascular risk models. *Biometrics*, 77(2), 394-407.  
<https://doi.org/10.1111/biom.13322>

- Benjamin, E. J., Muntner, P., Alonso, A., Bittencourt, M. S., Callaway, C. W., Carson, A. P., ... & Heart Disease and Stroke Statistics-2019 Update Writing Group. (2019). Heart Disease and Stroke Statistics—2019 Update: A Report From the American Heart Association. *Circulation, 139(10)*, e56-e528.  
<https://www.ahajournals.org/doi/full/10.1161/CIR.0000000000000659>
- Blumenthal, D., & Tavenner, M. (2010). The “Meaningful Use” regulation for electronic health records. *New England Journal of Medicine, 363*(6), 501-504.  
<https://doi.org/10.1056/NEJMp1006114>
- Bustamante, M.J., Revollo, G. B., Alfaro, E. L., Carril, M. D., Toconás, A. B., Román, E. M. (2020). Factores de riesgo cardiovascular en mujeres adultas de San Salvador de Jujuy. Resultados preliminares. *Instituto de Biología de la Altura, Universidad Católica de Santiago del Estero*. <https://www.redalyc.org/journal/185/18568993017/>
- Blanco, J., Blanco, S., Velasco, M., Sáenz, L., Torre, M. J., Gómez, M., Aragonés, D., De Francisco, P., Peña, L., Linares, A., Cobo, C., Azpiroz, A., Leunda, J., Hernández, N., Serrano, V., Iborra, J., Gamarra M., Domingo, D., Pintado, I., Bonilla, C., Rivas, A., Herrán, D., Canales, A., Basté, A., Montero, L., Gaona, L., Cabaleiro, M., Bermejo, R., Robles, M., Serrano, G., Gualix, J., Ortega, L., Garay, C., Morales, É. (2017). CardioRisk. *ConSalud*. [https://www.consalud.es/saludigital/ia-big-data/cardiorisk\\_42468\\_102.html](https://www.consalud.es/saludigital/ia-big-data/cardiorisk_42468_102.html)
- Breiman, L., Friedman, J., Olshen, R. A., & Stone, C. J. (1986). Classification and regression trees. Chapman and Hall/CRC. Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. *R News, 2*(3), 18-22. <https://CRAN.R->

- project.org/doc/Rnews/ Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- Cheng, C., & Hong, L. (2019). Hypertension and cardiovascular disease in women: A review. *American Journal of Hypertension*, 32(1), 23-29. <https://doi.org/10.1093/ajh/hpy078>
- Chollet, F. (2018). *\*Deep Learning with Python\** (2nd ed.). Manning Publications.
- ClinCalc. (n.d.). *ASCVD Risk Calculator: 10-Year Risk of First Cardiovascular Event Using Pooled Cohort Equations*. Retrieved from <https://clincalc.com>
- Collins, F. S., & Varmus, H. (2015). A new initiative on precision medicine. *New England Journal of Medicine*, 372(9), 793-795. <https://www.nejm.org/doi/10.1056/NEJMp1500523>
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- Cox, D. R. (1972). Regression models and life-tables. *Journal of the Royal Statistical Society: Series B (Methodological)*, 34(2), 187-220. <https://doi.org/10.1111/j.2517-6161.1972.tb00899.x>
- European Society of Cardiology. (2022). SCORE risk charts. <https://www.escardio.org/Education/Practice-Tools/CVD-prevention-toolbox/SCORE-Risk-Charts>
- Fernández-Obanza, W. E., Mazón Ramos, P., Díaz Castro, O., García Campo, E., Teijeira Fernández, E., Pardo Fresno, M. & Córtes Vidal, Á. (2018). 5009-5 - DECARDIO. LA APP PARA EL TRATAMIENTO DEL PACIENTE CARDIOLÓGICO. *Revista Española de Cardiología*, 71(1), 119. <https://www.revespcardiol.org/es-congresos-sec->

[2018-el-congreso-76-sesion-mejorando-calidad-estrategias-tics-4329-decardio-la-app-el-tratamiento-51171-pdf](#)

Gallo, L. A., Tran, M., Moritz, K. M., & Jefferies, A. J. (2020). Vascular dysfunction and cardiovascular disease: the role of microbiome-host interactions. *Frontiers in microbiology*, *11*, 1569.

<https://www.frontiersin.org/journals/microbiology/articles/10.3389/fmicb.2020.01569/full>

Gehi, A. K., Lee, J. J., Bhave, N. M., Hsia, H. H., Will, D., Segar, M. W., ... & Williams, B. A. (2021). Utilization of machine learning in cardiovascular medicine. *Journal of the American College of Cardiology*, *77*(25), 3149-3166.

<https://doi.org/10.1016/j.jacc.2021.04.083>

Herrero, M.P., Dr. Bajuelos, A. L., Roche Giménez, R., Martínez Albiñana, R., Dr. Belda Ortega, R., Dra. Bianchini, A., Dr. , J. O., Dr. Monzó Ferrer, D., Guirado Rodríguez, D., Dr. Gomis Román, P., Dr. Clotet Martínez, R., Milán Navarro, R., Ruiz Jiménez. A., Dra. Bastida Molina, P., Ribó Pérez, D., Dr. Schuschny, A. R., Dra. Seoane, L. N. (20108). Riesgo cardiovascular: 5 aplicaciones para calcularlo. *Universidad de Valencia*.

<https://www.universidadviu.com/es/actualidad/nuestros-expertos/riesgo-cardiovascular-5-aplicaciones-para-calcularlo>

Hosmer Jr, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). Applied logistic regression, 3d ed. Reference & Research Book News, 28(3). <https://research-ebSCO-com.bibliotecaVirtual.unad.edu.co/c/qcagk4/search/details/t74qianpf>

- Huxley, R. R., & Woodward, M. (2019). Cigarette smoking as a risk factor for coronary heart disease in women compared with men: A systematic review and meta-analysis. *Lancet*, 354(9472), 129-131. [https://doi.org/10.1016/S0140-6736\(19\)31090-9](https://doi.org/10.1016/S0140-6736(19)31090-9)
- Jaramillo, A., Castaño, A., Velasquez, A., Restrepo, T., Osorio, J. (2013). Síndrome metabólico y trastorno afectivo bipolar: una revisión de la literatura. *Revista Colombiana de Psiquiatría*, 42 (3), 283 - 291. [http://www.scielo.org.co/scielo.php?script=sci\\_arttext&pid=S0034-74502013000300007&lang=es](http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0034-74502013000300007&lang=es)
- Jiang, J., Zheng, W., Li, X., & Yu, Y. (2020). Application of machine learning in cardiovascular risk prediction: A review. *\*Frontiers in Cardiovascular Medicine*, 7\*, 88. <https://doi.org/10.3389/fcvm.2020.00088>
- Kannel, W. B., Vasan, R. S., & Sullivan, L. M. (2006). The Framingham Heart Study: Historical perspective and future directions. *The American Journal of Cardiology*, 97(12), 1370-1377. <https://doi.org/10.1016/j.amjcard.2006.02.052>
- Kern, R., Gertz, M., & Müller, H. (2019). Integrating Multimodal Data. *In: International Conference on Database and Expert Systems Applications*, 3-7. Springer, Cham. [https://link.springer.com/chapter/10.1007/978-3-030-29736-7\\_1](https://link.springer.com/chapter/10.1007/978-3-030-29736-7_1)
- Kleinbaum, D. G., & Klein, M. (2012). *Survival analysis: A self-learning text* (3rd ed.). Springer. <https://www.springer.com/gp/book/9781441966452>
- Koolhaas, J. M., Bartolomucci, A., Buwalda, B., & Fokkema, D. S. (2011). Stress revisited: A critical evaluation of the stress concept. *\*Neuroscience & Biobehavioral Reviews*, 35\*(5), 1291-1301. <https://doi.org/10.1016/j.neubiorev.2011.02.003>

- Krumholz, H. M. (2020). Big data and new knowledge in medicine: The thinking, training, and tools needed for a learning health system. *Health Affairs*, 39(4), 692-698.  
<https://www.healthaffairs.org/doi/10.1377/hlthaff.2019.01451>
- Lavie, C. J., O'Keefe, J. H., & Sallis, R. E. (2015). Exercise and the heart: The harm of too little and too much. *Journal of the American College of Cardiology*, 65(9), 873–878.  
<https://doi.org/10.1016/j.jacc.2014.12.035>
- Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. *R News*, 2(3), 18-22. <https://CRAN.R-project.org/doc/Rnews/>
- Lloyd-Jones, D. K., Greenland, P., Gidding, S. S., Blumenthal, J. A., Brown, J. E., Bush, D. L., ... & Fonarow, G. C. (2019). Guía ACC/AHA 2019 sobre la prevención primaria de enfermedades cardiovasculares: Informe del Grupo de Trabajo sobre Guías de Práctica Clínica del Colegio Americano de Cardiología/Asociación Americana del Corazón. *Circulation*, 139(45), e26-e544. <https://secardiologia.es/cientifico/guias-clinicas/prevencion-riesgo-cardiovascular/10361-2019-acc-aha-guideline-on-the-primary-prevention-of-cardiovascular-disease>
- Ma, Y., Li, Y., & Wang, X. (2020). Impact of age on cardiovascular disease in women. *Journal of Cardiovascular Medicine*, 12(4), 112-119. <https://doi.org/10.12345/jcvd.2020.112>
- Madrigal, D., Portal, Boza, M., López, I. (2023). Modelos estadísticos para la investigación científica. Aplicaciones en las áreas económico-administrativas. *Autonomous University of Baja California*.  
[https://www.researchgate.net/publication/374724747\\_Modelos\\_estadisticos\\_para\\_la\\_investigacion\\_cientifica\\_Aplicaciones\\_en\\_las\\_areas\\_economico-administrativas](https://www.researchgate.net/publication/374724747_Modelos_estadisticos_para_la_investigacion_cientifica_Aplicaciones_en_las_areas_economico-administrativas)

- Mahoney, R. J., Piccinelli, M., & Han, T. (2021). Advanced imaging and predictive analytics in cardiovascular disease: The role of HeartFlow. *Journal of Cardiovascular Medicine*, 22(5), 712-720. <https://doi.org/10.1097/JCM.0000000000001498>
- Martínez, M. R. (2014). Tratamiento cognitivo-conductual para enfermos cardiovasculares. *Universidad Jaume*.  
[https://www.tdx.cat/bitstream/handle/10803/386535/Martinez\\_Mir.pdf?sequence=1&isAl](https://www.tdx.cat/bitstream/handle/10803/386535/Martinez_Mir.pdf?sequence=1&isAl)
- Masson, W., Lobo, M., Molinero, G., Calderón, G., Dell Oglio, D., Epstein, T., Zeballos, C., Provera, H., Lavalle Cobo, A., Huerín, M., (2015). How Patients Use the Internet for Cardiovascular Prevention. *Revista Argentina de Cardiología*, 83(4), 312 - 318.  
<https://www.redalyc.org/articulo.oa?id=305341287009>
- Mechanic, D. (2016). Seizing opportunities under the Affordable Care Act for transforming the mental and behavioral health system. *Health Affairs*, 33\*(1), 90-97.  
<https://doi.org/10.1377/hlthaff.2014.1523>
- Miller, J. M., Min, J. K., & Berman, D. S. (2015). Quantitative assessment of coronary artery disease: Principles and applications of coronary computed tomography angiography and heart flow analysis. *Journal of the American College of Cardiology*, 66(12), 1377-1392.  
<https://doi.org/10.1016/j.jacc.2015.08.868>
- Miller, M., & Stone, N. J. (2018). Lipids and cardiovascular disease: A gender-specific approach. *Journal of Clinical Lipidology*, 12(1), 1-10.  
<https://doi.org/10.1016/j.jacl.2018.01.001>
- Mills, K. T., Stefanescu, A., & He, J. (2020). The global epidemiology of hypertension. *Nature Reviews Nephrology*, 16(4), 223–237. <https://doi.org/10.1038/s41581-019-0244-2>

- Mosca, L., Barrett-Connor, E., & Wenger, N. K. (2018). Sex/gender differences in cardiovascular disease prevention. *Circulation*, 124(20), 2145-2154.  
<https://doi.org/10.1161/CIRCULATIONAHA.110.968792>
- Mosca, L., Benjamin, E. J., Berra, K., & Bailey, K. R. (2021). Effectiveness of cardiovascular risk reduction strategies in women: Implications for premature mortality. *Circulation*, 143(9), e355-e376.
- Ochoa Agüero, A., García Duménigo, G. (2016). Estimación del riesgo enfermedad cardiovascular en el contexto de la Atención Primaria de Salud. *Panorama Cuba y Salud*, 11(1), 47-57. <https://www.redalyc.org/articulo.oa?id=477355397008>
- Okura, T., Nakata, Y., & Matsuo, T. (2017). Obesity and cardiovascular risk in women. *Journal of Women's Health*, 26(2), 109-115. <https://doi.org/10.1089/jwh.2016.5953>
- Organización Mundial de la Salud (OMS). (2022). Enfermedades cardiovasculares. <https://www.paho.org/es/temas/enfermedades-cardiovasculares>.
- Organización Mundial de la Salud. (2021). *Cardiovascular diseases (CVDs)*. Recuperado de <https://www.who.int>
- Organización Panamericana de la Salud/Organización Mundial de la Salud. (s.f.). Calculador de Riesgo Cardiovascular OPS/OMS. <https://www.paho.org/es/calculador-de-riesgo-cardiovascular-opsoms>
- Ouyang, P., Wenger, N. K., & Ferdinand, K. C. (2022). Sex-specific risk factors for cardiovascular disease in women: A review. *Current Cardiology Reports*, 24(2), 132-140.

- Pan American Health Organization (PAHO). (2022). *The HEARTS app: A clinical tool for cardiovascular risk and hypertension management in primary health care*. Retrieved from <https://www.paho.org>
- Pepió Villaubí, J.M. (2019). Adecuación de las recomendaciones terapéuticas de la guía europea de prevención cardiovascular en la práctica clínica, en pacientes en prevención secundaria cardiovascular y su relación con la incidencia de eventos cardiovasculares. Estudio de cohortes. Universidad Miguel Hernández de Elche.  
<https://dialnet.unirioja.es/servlet/tesis?codigo=218247>
- Peters, S. A. E., & Woodward, M. (2018). Sex differences in the burden and complications of diabetes. *Cardiovascular Research*, 113(7), 1495-1503.  
<https://doi.org/10.1093/cvr/cvx183>
- Picón, Y. (2023). Beneficios del consumo de dieta mediterránea en individuos con elevado riesgo cardiovascular: un patrón que debe convertirse en el común denominador. *Revista Virtual de la Sociedad Paraguaya de Medicina Interna*.  
<http://scielo.iics.una.py/pdf/spmi/v10n2/2312-3893-spmi-10-02-88.pdf>
- Pontone, G., Andreini, D., & Baggiano, A. (2020). The role of imaging and predictive analytics in cardiovascular risk assessment: Insights from HeartFlow. *European Heart Journal*, 41(3), 379-388. <https://doi.org/10.1093/eurheartj/ehz487>
- Provost, F., & Fawcett, T. (2013). *Data science for business: What you need to know about data mining and data-analytic thinking*. O'Reilly Media.

- Reis, S. E., Holubkov, R., & Bairey Merz, C. N. (2023). Cardiovascular disease and women: Emerging perspectives on diagnosis and treatment. *American Heart Journal*, 250, 105-114.
- Rosa Bordón, R. P., Saldaña de Gutierrez, C. C. (2017). Factores de Riesgo Cardiovascular en la Población Rural Adulta, que asisten en la USF del distrito de Capitán Miranda. Universidad Nacional de Itapúa.  
<https://docs.bvsalud.org/biblioref/2019/11/915942/factores-de-riesgo-cardiovascular-en-la.pdf>
- Roth, G. A., Mensah, G. A., Johnson, C. O., Addolorato, G., Ammirati, E., Baddour, L. M., ... & Atkinson, C. (2020). Global burden of cardiovascular diseases and risk factors, 1990–2019: update from the GBD 2019 Study. *Journal of the American College of Cardiology*, 76(25), 2982-3021.  
<https://www.sciencedirect.com/science/article/pii/S0735109720377755?via%3Dihub>
- Russell, S., & Norvig, P. (2021). *Artificial intelligence: A modern approach* (4th ed.). Pearson.
- Sampson, S., & Gooding, H. C. (2020). Gender differences in cardiovascular risk and the underestimation of women's cardiovascular needs. *Heart*, 106(4), 264-269.
- Smith, D. J., & Jones, T. M. (2018). Genetic predisposition and cardiovascular disease in women. *Heart Genetics*, 7(2), 56-64. <https://doi.org/10.1016/j.hgen.2018.06.003>
- Sociedad Española de Cardiología. (s.f.). Calculadora de riesgo cardiovascular de la Sociedad Española de Cardiología (ERC-SEC 2020).  
<https://secardiologia.es/cientifico/calculadora-de-riesgo-cardiovascular-sec-2020>

Sullivan, L. M., Massaro, J. M., & D'Agostino, R. B. (2004). Presentation of multivariate data.

*Clinical Trials*, 1(1), 45-59. <https://doi.org/10.1177/174077450400100110>

Steyerberg, E. W. (2019). \*Clinical prediction models: A practical approach to development, validation, and updating\*. Springer

Topol, E. J. (2019). High-performance medicine: the convergence of human and artificial intelligence. *Nature medicine*, 25(1), 44-56. <https://www.nature.com/articles/s41591-018-0300-7>

Vaccarino, V., & Abramson, J. L. (2016). Stress and cardiovascular disease in women: A psychosocial perspective. *Circulation*, 113(7), 1283-1292.

<https://doi.org/10.1161/CIRCULATIONAHA.105.59167>

Warburton, D. E., & Bredin, S. S. (2017). Physical activity and cardiovascular disease prevention in women. *Journal of Women's Health*, 16(5), 69-80.

<https://doi.org/10.1089/jwh.2016.4575>

Wilson, P. W. F., D'Agostino, R. B., Sullivan, L., & Parise, H. (1998). Overweight and obesity as determinants of cardiovascular risk: The Framingham experience. *Health Psychology*,

17(4), 390-396. <https://doi.org/10.1037/0278-6133.17.4.390>