



**UNIVERSIDAD DE CONCEPCIÓN  
FACULTAD DE INGENIERÍA  
DEPARTAMENTO DE INGENIERÍA ELECTRICA**



**APLICACIÓN MÓVIL PARA LA ESTIMACIÓN DE RIESGO DE  
ACCIDENTE CEREBROVASCULARES BASADO EN APRENDIZAJE  
AUTOMÁTICO**

POR

**Matías Ignacio Bucarey Echeverría**

Informe Final Memoria de Título presentada a la Facultad de Ingeniería de la Universidad de  
Concepción para optar al grado académico de Ingeniero Civil Biomédico

Profesor Guía  
Rosa Figueroa Iturrieta

Comisión  
Esteban Pino  
Gerónimo Bolado

Noviembre  
Concepción  
(Chile)

© 2024 Matías Ignacio Bucarey Echeverría

© 2024 Matías Ignacio Bucarey Echeverría

Se autoriza la reproducción total o parcial, con fines académicos, por cualquier medio o procedimiento, incluyendo la cita bibliográfica del documento.



## Agradecimientos

Primero, quiero expresar mi más profundo agradecimiento a mi familia, quienes me han brindado un apoyo incondicional y me han dado todas las oportunidades que han hecho posible llegar hasta aquí. Gracias por el amor, el cariño y el cuidado que siempre me muestran, por estar a mi lado en cada paso del camino y por ser el pilar más sólido en mi vida. Sin su respaldo y confianza en mí, nada de esto hubiera sido posible.

A mi polola, Francisca, muchas gracias. Desde el primer día que entramos a la universidad ha estado ahí, siendo un apoyo fundamental en cada momento y ayudándome a crecer, no solo como estudiante, sino también como persona. Gracias por tus palabras de aliento, por tu compañía incondicional y por hacer que crea en mí mismo, incluso en los momentos en los que yo mismo dudaba. Tu apoyo ha sido clave, y todo esto ha sido mucho más fácil y lindo porque has estado a mi lado.

A mis amigos y compañeros de universidad, gracias. Sin ustedes, esta etapa no habría sido tan divertida ni tan interesante. Han sido mi compañía en cada aventura, en cada carrete, en los momentos de llanto y, sobre todo, en las infinitas risas. Gracias por hacer de estos años una experiencia única, llena de memorias inolvidables.

Quiero agradecer también a la Burschenschaft Montania, un lugar que se ha convertido en mi segundo hogar. Más allá de lo académico, allí he aprendido valores como el compromiso, el honor (Ehre), la amistad (Freundschaft) y la rectitud (Recht). Estos valores me han ayudado a forjar mi carácter y seguir adelante con mis metas. Es un lugar que llevaré siempre en el corazón.

Agradecerles a todos los académicos que me han acompañado en este camino. En especial, a mi profesora guía, Rosa Figueroa, quien ha sido una fuente constante de apoyo y orientación durante este último proceso. Gracias por su paciencia, por enseñarme y por acompañarme en esta última etapa universitaria.

Muchas gracias a todos. Este logro no hubiera sido posible sin el apoyo, el cariño y la presencia de cada uno de ustedes.

## Resumen

La presente memoria de título se enfoca en el desarrollo de una aplicación móvil para la estimación del riesgo de accidente cerebrovascular (ACV) utilizando modelos de Machine Learning (ML). La incidencia de ACV es una problemática significativa a nivel mundial, dada su alta tasa de mortalidad y las secuelas que provoca en los sobrevivientes. Por ello, una herramienta de evaluación temprana y accesible es fundamental para facilitar la prevención y el monitoreo de esta afección.

La aplicación, desarrollada en Android Studio y basada en el modelo de Red Neuronal Artificial (ANN), permite al usuario ingresar datos personales y recibir una estimación probabilística sobre su riesgo de sufrir un ACV. La elección del modelo ANN, junto con la integración de métodos como el undersampling para el balance de clases, demostró ser la opción más efectiva para alcanzar resultados confiables y específicos en el contexto del conjunto de datos disponible. A pesar del desbalance de clases y otras limitaciones de los datos, el modelo mostró una capacidad adecuada para detectar posibles casos de riesgo, priorizando el recall sobre la especificidad, aspecto clave en aplicaciones de salud donde es preferible minimizar los falsos negativos.

La aplicación fue evaluada mediante múltiples métricas (accuracy, precisión, recall, especificidad, F1-score y AUC-ROC), y los resultados demostraron un buen desempeño, sin sobreajuste, según lo indicado por los gráficos de pérdida de entrenamiento y validación. Esto confirma la consistencia del modelo y su adecuación para estimar el riesgo de ACV en distintos perfiles de usuario.

Entre las conclusiones de este proyecto, se destaca que el modelo de red neuronal artificial implementado en la aplicación cumple satisfactoriamente su propósito de estimar el riesgo de accidente cerebrovascular, proporcionando resultados confiables y específicos basados en los datos ingresados por el usuario. La herramienta es particularmente útil para la predicción temprana de riesgos de ACV, priorizando el recall en la identificación de casos de riesgo, lo cual es crucial en el ámbito de la salud.

## Abstract

The present project focuses on the development of a mobile application for estimating the risk of stroke using Machine Learning models. The incidence of strokes is a significant global issue due to its high mortality rate and the lasting impact it has on survivors. Therefore, an accessible and early assessment tool is essential for facilitating the prevention and monitoring of this condition.

The application, developed in Android Studio and based on an Artificial Neural Network (ANN) model, allows users to input personal data and receive a probabilistic estimation of their stroke risk. The choice of the ANN model, along with the integration of methods such as undersampling for class balancing, proved to be the most effective option for achieving reliable and specific results given the available dataset. Despite the class imbalance and other data limitations, the model showed adequate capacity to detect potential risk cases, prioritizing recall over specificity, a crucial aspect in health applications where minimizing false negatives is preferable.

The application was evaluated using multiple metrics (accuracy, precision, recall, specificity, F1-score, and AUC-ROC), and the results demonstrated strong performance without overfitting, as indicated by the training and validation loss graphs. This confirms the robustness of the model and its suitability for estimating stroke risk across different user profiles.

Among the conclusions of this project, it is highlighted that the Artificial Neural Network model implemented in the application successfully fulfills its purpose of estimating the risk of stroke, providing reliable and specific results based on the data entered by the user. The tool is particularly useful for the early prediction of stroke risk, prioritizing recall in identifying high-risk cases, which is crucial in the healthcare field.

## Tabla de Contenidos

<b>CAPÍTULO 1. INTRODUCCIÓN .....</b>	<b>1</b>
1.1. INTRODUCCIÓN GENERAL.....	1
1.2. DEFINICIÓN DEL PROBLEMA.....	2
1.3. OBJETIVOS.....	3
1.3.1 <i>Objetivo General</i> .....	3
1.3.2 <i>Objetivos Específicos</i> .....	3
1.4. ALCANCES Y LIMITACIONES.....	3
1.5. TEMARIO.....	3
<b>CAPÍTULO 2. MARCO TEÓRICO .....</b>	<b>5</b>
2.1. INTRODUCCIÓN.....	5
2.2. ACCIDENTE CEREBROVASCULAR.....	5
2.2.1 <i>Accidente Cerebrovascular Isquémico</i> .....	5
2.2.2 <i>Accidente Cerebrovascular Hemorrágico</i> .....	5
2.2.3 <i>Factores de Riesgo</i> .....	6
2.3. MACHINE LEARNING.....	6
2.3.1 <i>Adquisición de Datos</i> .....	7
2.3.2 <i>Preprocesamiento de Datos</i> .....	7
2.3.3 <i>Selección de Características</i> .....	8
2.3.4 <i>Entrenamiento del Modelo</i> .....	8
2.3.5 <i>Evaluación del Modelo</i> .....	9
2.3.6 <i>Algoritmos de Clasificación</i> .....	10
2.4. ANDROID STUDIO.....	12
<b>CAPÍTULO 3. REVISIÓN BIBLIOGRÁFICA .....</b>	<b>13</b>
3.1. INTRODUCCIÓN.....	13
3.2. MODELOS DE PREDICCIÓN DE ACV.....	13
3.3. NUEVAS TECNOLOGÍAS EN EL ÁREA DE LA SALUD.....	14
3.4. DISCUSIÓN.....	14
<b>CAPÍTULO 4. METODOLOGÍA.....</b>	<b>16</b>
4.1. INTRODUCCIÓN.....	16
4.2. METODOLOGÍA.....	16
4.2.1 <i>Adquisición de Datos</i> .....	16
4.2.2 <i>Preprocesamiento de los Datos</i> .....	17
4.2.3 <i>Selección de Características</i> .....	18
4.2.4 <i>Modelos de Clasificación</i> .....	20

4.2.5	<i>Evaluación</i> .....	22
4.2.6	<i>Aplicación Móvil</i> .....	22
<b>CAPÍTULO 5. RESULTADOS .....</b>		<b>23</b>
5.1.	INTRODUCCIÓN .....	23
5.2.	DESCRIPCIÓN DE LOS ESCENARIOS DE EVALUACIÓN .....	23
5.3.	TABLA DE RESULTADOS .....	23
5.4.	ELECCIÓN DEL MODELO .....	24
5.5.	IMPLEMENTACIÓN DEL MODELO .....	27
<b>CAPÍTULO 6. CONCLUSIONES .....</b>		<b>29</b>
6.1.	CONCLUSIONES .....	29
6.2.	TRABAJO A FUTURO.....	29
<b>CAPÍTULO 7. GLOSARIO.....</b>		<b>31</b>
<b>CAPÍTULO 8. REFERENCIAS.....</b>		<b>32</b>



## Lista de Tablas

Tabla 4.1. Descripción del Conjunto de Datos.....	16
Tabla 4.2. Hiperparámetros sincronizados para cada Modelo .....	21
Tabla 5.1. Métricas Modelo Support Vector Machine.....	23
Tabla 5.2. Métricas Modelo TabNet .....	24
Tabla 5.3. Métricas Modelo Red Neuronal Artificial .....	24
Tabla 5.4. Ejemplos de Entrada y Resultado del Estimador de Riesgo ACV.....	28



## Lista de Figuras

Figura 2.1. Proceso Machine Learning .....	7
Figura 2.2. Tipos de Algoritmos de Machine Learning .....	9
Figura 4.1. Distribución de Datos BMI.....	18
Figura 4.2. Mapa de Calor de Correlación de Spearman .....	19
Figura 4.3. Gráfico de Importancia de las Características .....	19
Figura 5.1. Métricas ANN.....	25
Figura 5.2. Matriz de Confusión ANN.....	26
Figura 5.3. Curva ROC-AUC ANN .....	26
Figura 5.4. Gráfico de Pérdida en Entrenamiento y Validación por Épocas .....	27
Figura 5.5. Aplicación Móvil “Estimación Riesgo ACV” .....	27



## Capítulo 1. Introducción

---

### 1.1. Introducción General

De acuerdo con la Organización Mundial de la Salud (OMS), anualmente 15 millones de personas sufren un accidente cerebrovascular, de las cuales 5 millones de estas quedan con secuelas permanentes y otras 5 millones de personas mueren [1].

Al momento de ocurrir este tipo de afección, los efectos que produce varían dependiendo de la parte del cerebro donde se localiza el daño. Por ejemplo, si el ACV se localiza en el lado izquierdo del cerebro, la persona afectada podría llegar a experimentar parálisis en el lado derecho del cuerpo, problemas para comunicarse, pérdida de memoria y presentar un comportamiento lento y cauteloso. En cambio, si esta afección se produce en el lado derecho del cuerpo, el paciente puede presentar un comportamiento errático, pérdida de visión, pérdida de memoria y parálisis en el lado izquierdo del cuerpo. Dependiendo de la severidad del ACV, este puede afectar a ambos lados del cerebro y con esto el paciente puede generar el síndrome de enclaustramiento, donde el paciente no puede hablar ni realizar acciones desde el cuello hacia abajo [2].

La detección temprana de los accidentes cerebrovasculares es crucial, ya que esta condición es "tiempo-dependiente". Esto significa que cuanto más rápido se identifique y se actúe ante un ACV, mayores serán las posibilidades de supervivencia del paciente y de minimizar las secuelas a largo plazo [3].

En los últimos años, la literatura reporta avances en ML como una herramienta que puede ayudar a la detección temprana de accidentes cerebrovasculares. Este campo ha tenido un gran desarrollo gracias a la invención de nuevos algoritmos y a la mejora de los antiguos. Esta evolución ha permitido que los algoritmos cada vez tengan mejor desempeño y por ende sean más confiables y pueden tener una mayor repercusión en el área de la salud, donde los resultados necesitan ser extremadamente precisos [4].

Con el fin de seguir aportando en la detección temprana de los ACV, es de suma importancia seguir creando nuevos modelos que ayuden en un futuro a salvar la vida de las personas que sufren este tipo de afección.

## 1.2. Definición del problema

Se realizó un catastro de accidentes cerebrovasculares del año 2019 para la World Stroke Organization (WSO) [5]. En este informe se muestra que en ese año hubieron más de 12,2 millones de personas que sufrieron esta afección. Esto en términos monetarios equivale a más de US\$ 721 mil millones, lo que representa el 0,66% de producto interno bruto (PIB) mundial. La suma de dinero toma en cuenta distintos gastos directos e indirectos relacionados con el tratamiento del ACV, la pérdida de productividad del paciente y los costos del cuidado de este a largo plazo. Del total de personas que sufrieron un ACV el año 2019, 5,5 millones fallecieron y hubo 143.5 millones de años de vida ajustados por discapacidad (AVAD), un indicador que combina el tiempo vivido con discapacidad y el tiempo perdido por muerte prematura.

La literatura indica que el diagnóstico, y por lo tanto la predicción temprana de una afección como un ACV, es de suma importancia, ya que esto permite un tratamiento efectivo y mejores resultados en la rehabilitación del paciente. La detección temprana de un ACV permite mermar la probabilidad de que el paciente sufra daños cerebrales adicionales y significativos. Esto aumenta las posibilidades de que el paciente sobreviva y previene futuros eventos cerebrovasculares [6]. Ante esta problemática, los modelos predictivos han mostrado ser un gran apoyo en el diagnóstico y tratamiento de enfermedades neurológicas y neurovasculares.

El ML junto al Deep Learning (DL) tienen además un gran potencial para analizar distintas imágenes, como por ejemplo, de una tomografía por emisión de positrones (PET) y con esto generar modelos predictivos para distintas condiciones neurológicas [7]. Esta Memoria de Título (MT) tiene como objetivo generar una herramienta para apoyar el diagnóstico temprano de un ACV utilizando modelos de aprendizaje automático.

## 1.3. Objetivos

### 1.3.1 Objetivo General

Desarrollar una aplicación en Android que permita estimar el riesgo de padecer un accidente cerebrovascular utilizando modelos de aprendizaje automático.

### 1.3.2 Objetivos Específicos

- Desarrollar una aplicación en Android que permita embeber código de Machine Learning en Python.
- Desarrollar algoritmo que permita calcular el riesgo de padecer un accidente cerebrovascular utilizando aprendizaje automático.
- Evaluación del algoritmo que permita calcular el riesgo de padecer un accidente cerebrovascular utilizando aprendizaje automático.

## 1.4. Alcances y Limitaciones

- i. Esta MT se enfocó en desarrollar una aplicación en Android que presente un estimador de riesgo de padecer un accidente cerebrovascular. Dado lo anterior, el diseño de la aplicación es básico y no incluyó otro tipo de funcionalidades.
- ii. Esta MT utilizó un set de datos de libre disposición desde la plataforma Kaggle, por lo que el resultado del algoritmo de estimación estuvo directamente ligado a la calidad de los datos presentes en este.

## 1.5. Temario

- (i) Capítulo 1: Introducción general del trabajo, donde se indican los objetivos y alcances del proyecto.
- (ii) Capítulo 2: En esta sección se tiene el marco teórico, en el cual se entrega contexto sobre el tema y las tecnologías que se han desarrollado en el área. Además, se tiene una discusión en la que se describe la información más relevante del análisis bibliográfico.
- (iii) Capítulo 3: Revisión del estado del arte para poder elegir los mejores métodos de clasificación y así entrenar de manera exitosa el modelo a crear.
- (iv) Capítulo 4: Materiales y métodos utilizados para este proyecto.

(v) Capítulo 5. En este capítulo se muestran los resultados del estimador de riesgo de padecer un ACV.

(vi) Capítulo 6: Se podrán encontrar las conclusiones del proyecto.



## Capítulo 2. Marco Teórico

---

### 2.1. Introducción

Este capítulo tiene como objetivo proporcionar la base conceptual del trabajo realizado, abordando las teorías y conceptos clave que sustentan el desarrollo de la aplicación móvil para predecir el riesgo de padecer un accidente cerebrovascular.

### 2.2. Accidente Cerebrovascular

Un ACV, es una afección que es ocasionada por el bloqueo de alguna arteria del cerebro o por la ruptura de estas. Los accidentes cerebrovasculares son una emergencia de vida o muerte, ya que mientras más tiempo pase la persona afectada sin atención, menor es la probabilidad de supervivencia y mayor las posibilidades de que sufra secuelas a largo plazo, como daño cerebral permanente o discapacidad física, dado la falta de irrigación sanguínea en el cerebro [8]. Como el cerebro controla diferentes áreas del cuerpo, existen diferentes síntomas que ayudan a detectar cuando una persona está sufriendo un ACV, tales como, debilidad o parálisis en un lado del cuerpo, afasia, pérdida de control muscular en un lado del rostro, dificultad para hablar, entre otros [9].

#### 2.2.1 Accidente Cerebrovascular Isquémico

Este es uno de los dos tipos de ACV y el más común, ocurriendo en aproximadamente un 87% de todos los accidentes cerebrovasculares [10]. Las causas principales de este tipo de ACV es la aterosclerosis, que es una enfermedad en la cual se forman placas de grasa, colesterol, calcio y otras sustancias en las arterias, lo que provoca que estas se hagan más angostas y por lo tanto, más susceptibles a una trombosis o un embolismo cerebral [11]. El tratamiento de urgencia para este tipo de afección es remover el coágulo o émbolo a través de un procedimiento quirúrgico, el cual puede ser ayudado con medicamentos trombolíticos [12].

#### 2.2.2 Accidente Cerebrovascular Hemorrágico

Este tipo de ACV ocurre debido a la debilitación o taponamiento y posteriormente ruptura de los vasos sanguíneos que rodean el cerebro, causando un sangrado y, por consiguiente, una compresión en los tejidos cerebrales y también en los tejidos adyacentes a este [13]. Los accidentes cerebrovasculares hemorrágicos son asociados a una morbilidad severa y a una alta mortalidad. Se

pueden clasificar en hemorragia intracerebral, la cual se produce dentro del cerebro, y hemorragia subaracnoidea, que se ubica entre los tejidos internos y externos que recubren el cerebro [14].

### 2.2.3 Factores de Riesgo

Cuando se habla de factores de riesgo de un ACV, se hace referencia a algo que incrementa las posibilidades de sufrir este tipo de afección. Existen factores de riesgo en los cuales no se puede tener el control y otros que si se pueden controlar [15]. En varios casos, los accidentes cerebrovasculares isquémicos y hemorrágicos tiene factores de riesgo similares, tales como diabetes, hipertensión y colesterol alto, pero también tienen factores de riesgo específicos, como la enfermedad coronaria, para el caso de un ACV isquémico que aumenta la probabilidad de generar coágulos sanguíneos, y el consumo de anticoagulantes, que aumentan la probabilidad de que ocurra un ACV hemorrágico.

Según la World Stroke Organization [5], existen 4 categorías las cuales engloban los factores de riesgo:

- Factores de riesgo metabólicos: Hipertensión, diabetes, obesidad, dislipidemia y enfermedad renal crónica.
- Factores de riesgo conductuales: tabaquismo, consumo excesivo de alcohol, falta de actividad física y dieta poco saludable.
- Factores de riesgo ambientales: Contaminación del aire, exposición al plomo y cambios climáticos.
- Factores de riesgo genéticos y hereditarios: antecedentes familiares de ACV, enfermedades cardiacas y trastornos de la coagulación sanguínea.

### 2.3. Machine Learning

El ML es una rama de la Inteligencia Artificial (IA) que trata de imitar la forma en que las personas piensan mediante el uso de datos y algoritmos. Algunos ejemplos de productos que usan ML es Netflix y los vehículos autónomos. Este tipo de IA está fuertemente relacionado con la ciencia de datos la cual es necesaria para el procesamiento de Big Data [16].



**Figura 2.1. Proceso Machine Learning**

El ML tiene un proceso el cual mejora constantemente el modelo mediante los pasos que se muestran en la Figura 2.1 y que se explican a continuación:

### 2.3.1 Adquisición de Datos

Obtener datos de diversas fuentes de información, como bases de datos, estudios académicos, archivos y otras plataformas, es fundamental para asegurar la calidad y confiabilidad de un análisis. La importancia de esta etapa radica en que los modelos de Machine Learning dependen directamente de la calidad y cantidad de los datos. en el ámbito médico, el acceso limitado a datos reales y longitudinales puede ser una barrera significativa para el desarrollo de modelos predictivos robustos [17].

### 2.3.2 Preprocesamiento de Datos

En esta etapa se evalúa la calidad de los datos para asegurarse que estén completos y que sean precisos.

Alguno de los problemas que pueden surgir y que se debe solucionar son los datos faltantes o incompletos, datos incorrectos o inexactos y el desbalance de clases. Para solucionar estos problemas existen diferentes soluciones para imputar los datos. Estos métodos van desde encontrar el mejor valor utilizando la mediana, media, la moda de los datos, entre otros modelos más sofisticados [18].

También, puede surgir el problema un problema con el balance de las clases. Este se presenta cuando una o más clases tienen significativamente más muestras que otras, lo que puede causar que los modelos se inclinen hacia la clase mayoritaria y disminuya su capacidad para predecir correctamente las clases minoritarias [19].

Existen varios métodos para solucionar este problema. Uno de los más utilizados es SMOTE (Synthetic Minority Over-sampling Technique), que genera nuevas muestras sintéticas para la clase minoritaria, creando un balance entre las clases sin replicar las muestras existentes. Otra técnica es el undersampling, que consiste en reducir el número de muestras de la clase mayoritaria de manera

aleatoria, equilibrando así la cantidad de datos entre las clases. Este enfoque puede ser eficaz, aunque existe el riesgo de eliminar datos relevantes [20].

### 2.3.3 Selección de Características

Se seleccionan las características más importantes del set de datos, con el objetivo de mejorar el futuro rendimiento del modelo de ML. Este proceso se puede realizar mediante diferentes métodos como los de filtro, wrapper o métodos embebidos [21].

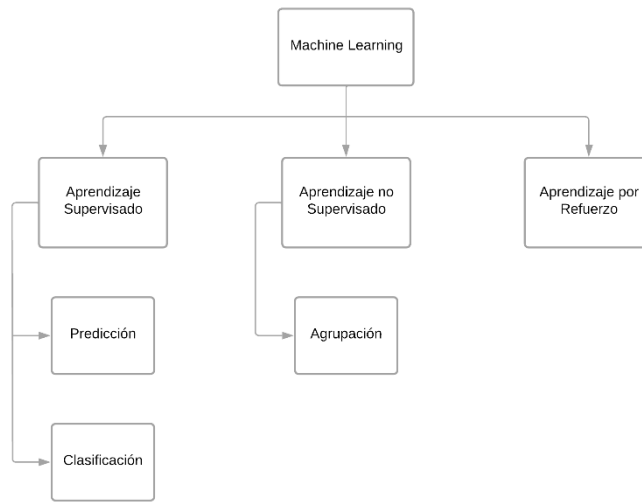
Dentro de los métodos de filtro para la selección de características, se encuentran técnicas como Feature Importance (importancia de las características), las correlaciones de Pearson y Spearman, entre otras [22]. El método de Feature Importance asigna un valor a cada característica en función de su relevancia en las predicciones de un modelo. Este valor indica la contribución de cada característica a la clasificación, sin importar si la relación es lineal o no lineal, generalmente utilizando algoritmos basados en árboles de decisión [23]. La correlación de Pearson y la correlación de Spearman son técnicas utilizadas para medir la relación entre dos variables cuantitativas. La correlación de Pearson es una prueba que asume que los datos son continuos y siguen una distribución normal. Evalúa relaciones lineales entre las variables. Por otro lado, la correlación de Spearman no requiere que los datos sigan una distribución específica y se utiliza cuando los datos no están distribuidos normalmente [24].

### 2.3.4 Entrenamiento del Modelo

En este punto se utilizan los algoritmos de clasificación. Estos son programas que aprenden de los datos que se le entregan, predicen la variable de salida y mejoran el rendimiento del modelo que se desea entrenar. Existen 3 tipos de algoritmos en machine learning, los algoritmos de aprendizaje supervisados, aprendizaje no supervisados y aprendizaje por reforzamiento, los cuales se muestran en la Figura 2.2 [25].

Además, para asegurar una evaluación más fiable del rendimiento del modelo, se implementa la validación cruzada. Este método de remuestreo de datos es utilizado para seleccionar modelos y evaluar su capacidad de generalización. Una de las variantes más comunes es la validación cruzada k-fold, que divide los datos en k subconjuntos o "folds". El modelo se entrena en k-1 subconjuntos y

se evalúa en el subconjunto restante. Este proceso se repite  $k$  veces, asegurando que cada partición de datos se utilice para la validación [26].



**Figura 2.2. Tipos de Algoritmos de Machine Learning**

### 2.3.5 Evaluación del Modelo

Luego de entrenar los distintos modelos, se debe medir el rendimiento que obtuvieron. Esto se puede hacer con distintas métricas de evaluación, pero las más conocidas son [27], [28]:

- Accuracy: O en español “exactitud”, es la proporción de instancias que el modelo calificó correctamente en el conjunto de prueba. Su fórmula es la siguiente:

$$Accuracy = \frac{TP + TN}{TOTAL}$$

**TP: Verdaderos Positivos**

**TN: Verdaderos Negativos**

- Recall: Esta métrica mide la relación entre los verdaderos positivos y el total de veces que el algoritmo clasificó instancias positivas, sean verdaderas o no. Su fórmula es:

$$Recall = \frac{TP}{TP + FN}$$

**FN: Falsos Negativos**

- Especificidad: Evalúa la tasa de verdaderos negativos. Es el cociente de la división entre los valores predichos correctamente como negativos y los negativos totales.

$$Especificidad = \frac{TN}{TP + FP}$$

**FP: Falsos Positivos**

- **Precisión:** Es la tasa del total de los casos clasificados como positivos. En otras palabras, es la proporción de veces que una variable de salida positiva se califica como tal. Su fórmula es:

$$Precisión = \frac{TP}{TP + FP}$$

- **F1 Score:** Es una métrica de evaluación equilibrada que indica si el modelo es bueno para identificar casos positivos y negativos. Su fórmula es:

$$F1\ Score = 2 \times \frac{Recall \times Precisión}{Recall + Precisión}$$

- **Curva ROC-AUC:** La curva ROC muestra la relación entre la tasa de verdaderos positivos y falsos positivos para evaluar un modelo de clasificación. El AUC mide el área bajo la curva, indicando la capacidad del modelo para distinguir entre clases: un valor cercano a 1 es excelente, mientras que un valor de 0.5 sugiere rendimiento aleatorio [29].

### 2.3.6 Algoritmos de Clasificación

#### A. *Support Vector Machine*

El Support Vector Machine (SVM) o máquina de soporte vectorial es un algoritmo supervisado basado en marcos de aprendizaje estadístico que tiene como objetivo principal crear un hiperplano para segregar los conjuntos de datos en diferentes clases. Este hiperplano tiene como misión maximizar la distancia entre los vectores de soporte o puntos de apoyo de cada clase, que son los puntos que están más cercanos al hiperplano. Este algoritmo se puede aplicar a datos unidimensionales, con un hiperplano recto, bidimensionales, con un hiperplano curvo o multidimensionales, que el hiperplano pasa a ser una hipersuperficie.

El SVM es un algoritmo muy preciso para datos no lineales, ya que este permite transformar los datos a un espacio de mayor dimensión donde la separación es lineal mediante la función kernel [30]. Por lo general, para implementar un modelo de SVM en Python, se utiliza la biblioteca Sckit-learn, la cual cuenta con el modelo Support Vector Classifier (SVC). Este tiene distintos parámetros que permiten adaptar el modelo para un mejor rendimiento, dentro de los cuales están el parámetro de regularización, kernel, probabilidad, balance de clases, entre otros [31].

## **B. TabNet**

TabNet es una arquitectura de red neuronal profunda creada para trabajar con datos tabulares. Este utiliza un mecanismo de atención que selecciona las características más relevantes en cada paso de decisión. Gracias a esto, TabNet presenta una mayor interpretabilidad y un mejor uso de los recursos computacionales [32].

Con TabNet se innovó en la selección de características a nivel de instancia, esto implica que este modelo puede adaptarse dinámicamente a los datos de entrada y seleccionar características según el caso.

Para los datos tabulares, TabNet utiliza un aprendizaje no supervisado, lo que hace que se presente un mejor rendimiento al momento de haber un gran número de datos no etiquetados. También presenta una gran capacidad de preentrenamiento, por lo que logra aprender representaciones útiles de los datos antes de realizar tareas supervisadas, mejorando la precisión del modelo.

## **C. Redes Neuronales Artificiales (ANN)**

Las redes neuronales artificiales son sistemas que fueron creados en base al funcionamiento y estructura del cerebro humano. Estas se usan generalmente en tareas como el reconocimiento de patrones, problemas de clasificación y aplicaciones en distintas áreas como por ejemplo la medicina [33].

Las ANN están compuestas por neuronas artificiales. Estas últimas reciben múltiples entradas, luego las ponderan y calculan una salida basada en una función de activación, por ejemplo, la función sigmoide.

El aprendizaje de las redes neuronales artificiales se produce ajustando los pesos y umbrales de las neuronas a través de entrenamiento. Este tipo de modelos puede ser utilizado en aprendizaje supervisado y no supervisado [34].

Generalmente, este tipo de modelos pueden llegar a presentar sobreajuste, que ocurre cuando se ajusta demasiado a los datos de entrenamiento y pierde la capacidad de generalizar con datos nuevos. También presenta desafíos como su comportamiento inexplicable, la falta de una regla clara para diseñar su arquitectura, su dependencia del hardware potente, y la degradación gradual del rendimiento [35].

## 2.4. Android Studio

Android Studio es el entorno de desarrollo oficial proporcionado por Google para crear aplicaciones en Android. Este programa ofrece todas las herramientas necesarias para diseñar, programar, probar y publicar aplicaciones móviles. Está basado en IntelliJ IDEA, un software popular entre los desarrolladores, y está optimizado específicamente para trabajar con Android. Android Studio incluye funciones como un editor de código que ayuda a escribir de manera más eficiente, un simulador para probar aplicaciones sin necesidad de un dispositivo físico y un sistema de construcción que facilita el empaquetado y despliegue de las aplicaciones. Además, permite diseñar interfaces de usuario de manera visual y cuenta con herramientas de depuración que ayudan a identificar y corregir errores, mejorando la calidad y rendimiento de las aplicaciones desarrolladas [36].



## Capítulo 3. Revisión Bibliográfica

---

### 3.1. Introducción

Este capítulo ofrece una visión del estado del arte de la predicción de ACV utilizando modelos basados en ML. Se presentó una recopilación de los trabajos más recientes.

### 3.2. Modelos de Predicción de ACV

Los modelos de predicción de accidentes cerebrovasculares han avanzado significativamente con el uso de técnicas de aprendizaje automático, destacándose el Random Forest (RF), las redes neuronales artificiales y las máquinas de vectores de soporte. En el artículo [37], se evaluaron modelos como random forest, Decision Tree (DT) y SVM, obteniendo el RF la mayor precisión (95.3%), seguido por el modelo SVM (91.98%). Rahman y los demás autores exploraron redes neuronales profundas junto con algoritmos de boosting, observando que el Random Forest tuvo el mejor rendimiento en precisión (100%). Aunque las ANN lograron una precisión menor, del 88%, demostraron ser igualmente efectivas para identificar patrones complejos en los datos relacionados con ACV [38].


Dritsas y Trigka, por su parte, resaltaron la importancia de considerar métricas como el recall, especificidad, y el AUC además de la precisión para una evaluación completa del modelo, logrando altos valores de AUC y recall su modelo ANN, con 94% y 95% respectivamente [39]. Asimismo, en [40] emplearon regresión logística y árboles de decisión, combinados con SVM, demostrando que la combinación de estas técnicas mejora la precisión en la detección temprana mediante validación cruzada y selección de características. Así, aunque RF y otros métodos de ensamble lideran en precisión en algunos estudios, tanto ANN como SVM son herramientas clave en modelos predictivos, especialmente en datos complejos de ACV, y la consideración de múltiples métricas de evaluación permite una interpretación más completa del rendimiento del modelo.

TabNet se destaca en el análisis de datos tabulares al permitir interpretabilidad local y global mediante atención secuencial, siendo ideal para sectores como seguros y detección de fraude. Su estructura facilita la selección de características a nivel de instancia, ofreciendo ventajas sobre métodos tradicionales en precisión y comprensión del modelo [41], [42]. En el ámbito de la clasificación de fraudes, TabNet ha demostrado ser eficaz al integrarse en sistemas de decisión complejos, mejorando la detección de patrones sin necesidad de preprocesamiento extenso [43].

### 3.3. Nuevas Tecnologías en el Área de la Salud

En los últimos años, la adopción de tecnologías digitales y aplicaciones móviles en el sector salud ha aumentado notablemente, transformando la forma en que los pacientes y profesionales interactúan con los servicios de salud. Estas herramientas han tenido un impacto significativo en la mejora de diagnósticos, la optimización de procesos administrativos y el acceso a servicios de atención médica [44]. La inteligencia artificial y el aprendizaje automático han jugado un papel crucial, especialmente en la radiología, donde han mejorado la precisión y velocidad en el diagnóstico mediante el análisis automatizado de imágenes médicas, lo cual apoya directamente a los profesionales en la toma de decisiones clínicas [45]. La integración de estas tecnologías no solo optimiza los procesos clínicos, sino que también contribuye a una atención de salud más personalizada y eficiente [46].

Además, plataformas basadas en Big Data permiten analizar grandes volúmenes de información médica, lo que optimiza la gestión clínica y reduce errores administrativos. Este enfoque ha sido fundamental para la evolución de la Industria 4.0 en el ámbito de la salud, permitiendo mejoras en el análisis y la planificación de servicios de salud. Ejemplos específicos incluyen aplicaciones como Ada Health y Babylon Health, que utilizan IA para evaluar síntomas y proporcionar diagnósticos preliminares, mejorando así el acceso y calidad de atención mediante consultas virtuales y monitoreo continuo [47].



### 3.4. Discusión

En la revisión bibliográfica, se observó que tanto el support vector machine como las redes neuronales artificiales son ampliamente utilizados en la predicción de eventos de salud, destacándose por su precisión y robustez. Estos modelos fueron seleccionados debido a sus buenos resultados reportados en estudios previos relacionados con la predicción de enfermedades, demostrando una capacidad eficaz para identificar patrones en los datos. Un aspecto clave que inclinó la elección hacia SVM y ANN sobre otros modelos, como el random forest, fue la capacidad de ambos para proporcionar una probabilidad asociada al riesgo predicho. Esta funcionalidad es fundamental en el contexto del proyecto, cuyo objetivo es ofrecer al usuario una estimación del riesgo de padecer un accidente cerebrovascular de forma probabilística, permitiendo una mejor comprensión de la predicción.

Además, se decidió incluir TabNet en el conjunto de modelos debido a su diseño específico para manejar datos tabulares, como los presentes en este proyecto. Al ser un modelo creado para este tipo de datos, se esperaba que TabNet pudiera capturar patrones y relaciones en el conjunto de datos de manera eficiente.



## Capítulo 4. Metodología

---

### 4.1. Introducción

En este capítulo se explicará los materiales y metodologías que se utilizaron para crear la aplicación móvil con el fin de estimar el riesgo de sufrir un ACV en base a variables fisiológicas y sociodemográficas.

### 4.2. Metodología

#### 4.2.1 Adquisición de Datos

Para este proyecto se utilizó un conjunto de datos llamado “healthcare-dataset-stroke-data” que se encuentra en Kaggle, una plataforma en internet para ciencia de datos y machine learning que ofrece datos públicos, competencias y herramientas gratuitas para desarrollar y compartir modelos predictivos [48]. El set de datos a utilizar corresponde a un conjunto de ACV disponible en Kaggle que se originó en un evento hackathon de McKinsey & Company [49]. Este conjunto de datos escogido cuenta con 5110 filas (sujetos) y 12 columnas (variables). Entre estas variables se encuentran variables de tipo numéricas y categóricas. La Tabla 4.1 describe las variables del set de datos:

**Tabla 4.1. Descripción del Conjunto de Datos**

Variable	Tipo	Descripción
<b>Edad</b>	Numérico	Valor Mínimo: 1 Valor Máximo: 82
<b>Índice de Masa Corporal (BMI)</b>	Numérico	Valor Mínimo: 10 Valor Máximo: 97
<b>Nivel Promedio de Glucosa en Sangre</b>	Numérico	Valor Mínimo: 56 Valor Máximo: 271
<b>Genero</b>	Categórica	Masculino, Femenino, Otro


<b>Hipertensión</b>	Categorica	Si, No
<b>Enfermedad Cardiaca</b>	Categorica	Si, No
<b>Estado Civil</b>	Categorica	Casado, Soltero
<b>Tipo de Trabajo</b>	Categorica	Gubernamental, Niño, Nunca ha Trabajado, Privado, Independiente
<b>Tipo de Residencia</b>	Categorica	Rural, Urbana
<b>Estatus de Fumador</b>	Categorica	Fumador, Nunca ha Fumado, Dejó de Fumar, Desconocido
<b>ACV</b>	Categorica	Si, No

**Fuente:** Elaboración propia

#### 4.2.2 Preprocesamiento de los Datos

El preprocesamiento de datos es una etapa crucial para asegurar el correcto desempeño de un modelo de inteligencia artificial. En este caso, se realizó una evaluación inicial para identificar posibles factores que pudieran introducir ruido en el conjunto de datos. Se detectó que la variable índice de masa corporal presentaba valores faltantes, con 4909 datos disponibles de un total de 5110.

Para solucionar este problema, se optó por llenar los valores faltantes utilizando la mediana, ya que la distribución de los datos de la variable BMI no es lineal, como se puede observar en la Figura 4.1.



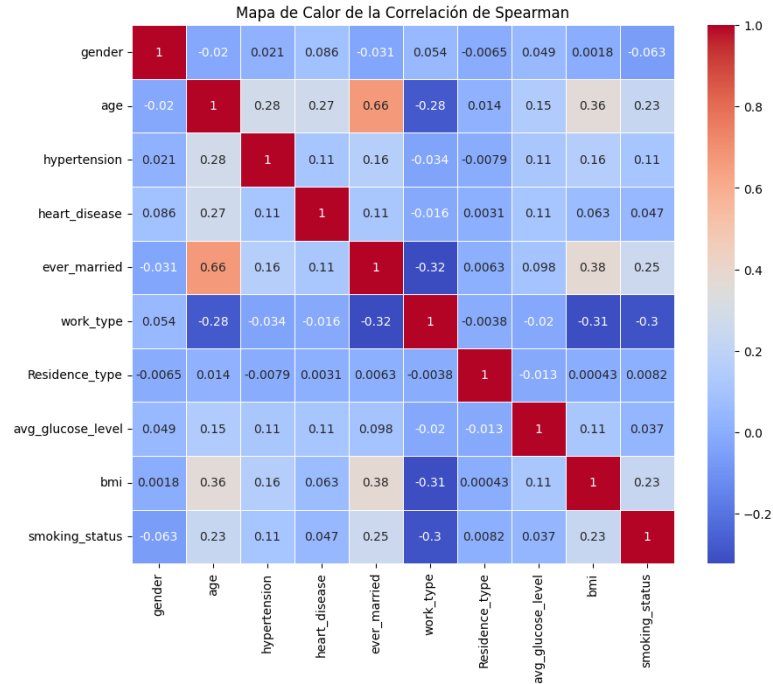
**Figura 4.1. Distribución de Datos BMI**

Después de resolver el problema de los datos faltantes en la variable BMI, se procedió a codificar las variables categóricas utilizando Label Encoder (LE). La elección de este método en lugar del Ordinal Encoder (OE) se debe a que los valores de estas variables no presentan un orden jerárquico ni lineal, por lo que LE es más adecuado para representar las categorías de forma numérica sin asignar un rango o nivel a las mismas.

### 4.2.3 Selección de Características

La selección de características en machine learning es un proceso clave para mejorar la precisión y eficiencia del modelo, ya que permite identificar las variables más relevantes y eliminar las irrelevantes o redundantes. Esto ayuda a reducir la dimensionalidad, optimizar el tiempo de entrenamiento y prevenir el sobreajuste.

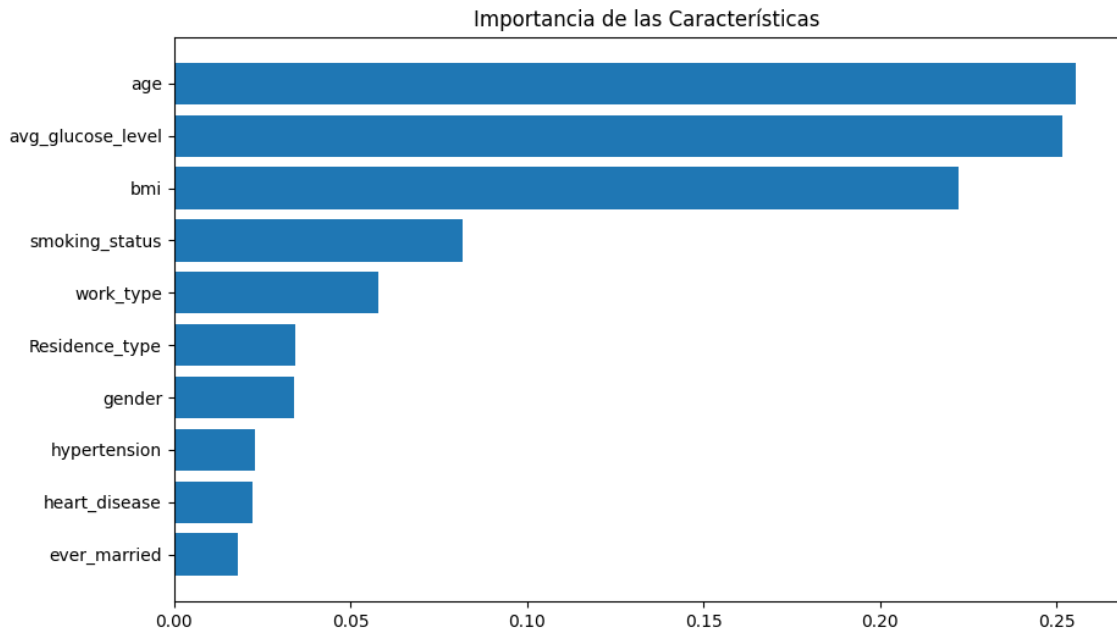
Durante la fase de selección de características, se utilizó la correlación de Spearman para identificar posibles relaciones entre las variables del conjunto de datos. Tras el análisis, se concluyó que no existían correlaciones significativas entre las variables como se muestra en la Figura 4.2.



**Figura 4.2. Mapa de Calor de Correlación de Spearman**

Además, se determinó que no era conveniente eliminar ninguna característica, ya que el conjunto de datos es pequeño y la eliminación de variables podría afectar negativamente el desempeño del modelo.

Adicionalmente, se implementó el Feature Importance basado en árboles de decisión para conocer cuáles son las características más relevantes del conjunto de datos, como se puede apreciar en la Figura 4.3.



**Figura 4.3. Gráfico de Importancia de las Características**

#### 4.2.4 Modelos de Clasificación

Tras la selección de características se procedió a resolver el problema de desbalance de clases presente en el conjunto de datos. Inicialmente se intentó resolver utilizando SMOTE, el cual no entregó resultados satisfactorios, por lo que se tomó la decisión de realizar un undersampling, que consiste en reducir la cantidad de muestras de la clase mayoritaria hasta igualarlas con el número de la clase minoritaria.

Antes de comenzar con el entrenamiento de los modelos seleccionados, se realizó la división del conjunto de datos en dos subconjuntos: uno de entrenamiento (80%, 398 sujetos) y otro de prueba (20%, 100 sujetos).

La fase de ajuste de hiperparámetros es un componente esencial en el desarrollo de modelos de machine learning, dado que los valores seleccionados pueden influir significativamente en el rendimiento final del modelo. En este trabajo, se utilizó SVM, TabNet y una ANN. En lugar de emplear un enfoque automatizado como GridSearchCV, los hiperparámetros fueron ajustados mediante un enfoque iterativo, probando diferentes configuraciones y evaluando su rendimiento en el conjunto de datos. Este proceso permitió identificar las combinaciones más adecuadas para optimizar el desempeño de cada modelo.

Para el SVM, se seleccionó un valor de  $C = 1$  y se activó la opción “probability = True”, mientras que el resto de los parámetros se mantuvieron en sus valores predeterminados. Estos ajustes controlan el grado de regularización y la posibilidad de obtener probabilidades como salida del modelo.

En el caso de TabNet, se utilizaron los hiperparámetros  $n_d = 16$ ,  $n_a = 32$  y  $n\_steps = 5$ , que controlan respectivamente las dimensiones de las capas de decisión y atención, y el número de pasos de decisión del modelo. Estos parámetros permiten que TabNet adapte su capacidad para modelar relaciones complejas en datos tabulares.

En el caso de la red neuronal artificial, se utilizó una arquitectura sencilla compuesta por varias capas densas. La primera capa contiene 256 neuronas con función de activación Sigmoide, adecuada para la clasificación binaria, seguida de una capa de Dropout con una tasa del 30% para prevenir el sobreajuste. Posteriormente, se añadió otra capa densa con 128 neuronas y activación Sigmoide, acompañada nuevamente de Dropout. La capa de salida también utiliza una función de activación sigmoide. Como optimizador, se empleó Adam con una tasa de aprendizaje de 0.001, y la función de pérdida seleccionada fue `binary_crossentropy`.

Además, para todos los modelos se utilizó validación cruzada, asegurando una evaluación consistente del rendimiento en diferentes subconjuntos de los datos.

En la Tabla 4.2, se pueden apreciar de mejor manera los hiperparámetros utilizados en cada modelo.

**Tabla 4.2. Hiperparámetros sincronizados para cada Modelo**

<b>Modelo</b>	<b>Hiperparámetros</b>	<b>Valor</b>
<b>SVM</b>	Parámetro de regulación (C)	1
	Kernel	“rbf”
	Probabilidad	“True”
<b>TabNet</b>	Dimensión de entrada (n_d)	16
	Dimensión de salida (n_a)	32
	Número de pasos (n_steps)	5
<b>ANN</b>	Capa de entrada	256
	Capa oculta	128
	Dropout	30%
	Función de activación	Sigmoide
	Tasa de aprendizaje	0.001

**Fuente:** Elaboración propia

#### 4.2.5 Evaluación

El modelo fue evaluado utilizando las métricas de accuracy (ACC), recall, F1-score, AUC-ROC, especificidad y precisión. Además, se incluyeron gráficos que muestran las pérdidas de entrenamiento y validación a lo largo de las épocas, junto con la matriz de confusión del modelo seleccionado.

#### 4.2.6 Aplicación Móvil

Para crear la aplicación móvil, se siguieron varios pasos clave. Primero, se diseñó una interfaz de usuario sencilla en Android Studio para permitir el ingreso de datos relevantes (como edad, BMI, glucosa, etc.) y se implementaron elementos visuales como campos de entrada, selectores y botones. Luego, se integró un modelo de aprendizaje automático, optimizado en TensorFlow Lite, para procesar los datos ingresados y calcular la probabilidad de sufrir un ACV. Finalmente, se realizaron pruebas y ajustes en la funcionalidad y presentación para asegurar que los resultados se muestren correctamente.



## Capítulo 5. Resultados

### 5.1. Introducción


En este capítulo se presentan los resultados obtenidos en el proyecto de desarrollo de una aplicación móvil para la estimación de riesgo de padecer un accidente cerebrovascular utilizando modelos de inteligencia artificial.

### 5.2. Descripción de los Escenarios de Evaluación

Se analizaron los resultados de cada modelo bajo tres configuraciones distintas del conjunto de datos: el conjunto de datos original, el conjunto de datos con aplicando SMOTE para balancear las clases, y el conjunto de datos con undersampling para igualar la cantidad de muestras entre clases. Para cada configuración, se comparó el rendimiento de los modelos con y sin validación cruzada, utilizando las siguientes métricas de evaluación: accuracy, precisión, recall, especificidad, F1 Score y Curva ROC-AUC.

### 5.3. Tabla de Resultados

En la Tabla 5.1, Tabla 5.2 y Tabla 5.3 se muestran los resultados obtenidos en cada enfoque de preprocesamiento y configuración de datos. Cada columna representa una configuración específica, y cada métrica fue evaluada con y sin validación cruzada.



**Tabla 5.1. Métricas Modelo Support Vector Machine**

Métricas SVC	Conjunto de Datos sin Balance de Clases		Conjunto de Datos con SMOTE		Conjunto de Datos con Undersampling	
	Con VC	Sin VC	Con VC	Sin VC	Con VC	Sin VC
<b>Accuracy</b>	0.95	0.95	0.71	0.72	0.75	0.80
<b>Precisión</b>	0.00	0.00	0.12	0.13	0.72	0.76
<b>Recall</b>	0.00	0.00	0.80	0.78	0.82	0.88
<b>Especificidad</b>	1.00	1.00	0.71	0.72	0.68	0.72
<b>F1-Score</b>	0.00	0.00	0.21	0.23	0.77	0.81
<b>AUC-ROC</b>	0.53	0.57	0.84	0.82	0.84	0.88

Fuente: Elaboración Propia

Tabla 5.2. Métricas Modelo TabNet

Métricas TabNet	Conjunto de Datos sin Balance de Clases		Conjunto de Datos con SMOTE		Conjunto de Datos con Undersampling	
	Con VC	Sin VC	Con VC	Sin VC	Con VC	Sin VC
<b>Accuracy</b>	0.95	0.95	0.77	0.91	0.64	0.75
<b>Precisión</b>	0.15	1.00	0.12	0.19	0.59	0.67
<b>Recall</b>	0.01	0.04	0.56	0.24	0.90	0.98
<b>Especificidad</b>	1.00	1.00	0.78	0.94	0.38	0.52
<b>F1-Score</b>	0.02	0.07	0.20	0.21	0.71	0.80
<b>AUC-ROC</b>	0.84	0.78	0.76	0.75	0.76	0.84

Fuente: Elaboración propia

Tabla 5.3. Métricas Modelo Red Neuronal Artificial

Métricas ANN	Conjunto de Datos sin Balance de Clases		Conjunto de Datos con SMOTE		Conjunto de Datos con Undersampling	
	Con VC	Sin VC	Con VC	Sin VC	Con VC	Sin VC
<b>Accuracy</b>	0.95	0.95	0.78	0.82	0.75	<b>0.84</b>
<b>Precisión</b>	0.00	0.00	0.13	0.14	0.71	<b>0.79</b>
<b>Recall</b>	0.00	0.00	0.60	0.46	0.84	<b>0.92</b>
<b>Especificidad</b>	1.00	1.00	0.79	0.84	0.66	<b>0.76</b>
<b>F1-Score</b>	0.00	0.00	0.21	0.21	0.77	<b>0.85</b>
<b>AUC-ROC</b>	0.83	0.81	0.78	0.76	0.82	<b>0.88</b>

Fuente: Elaboración propia

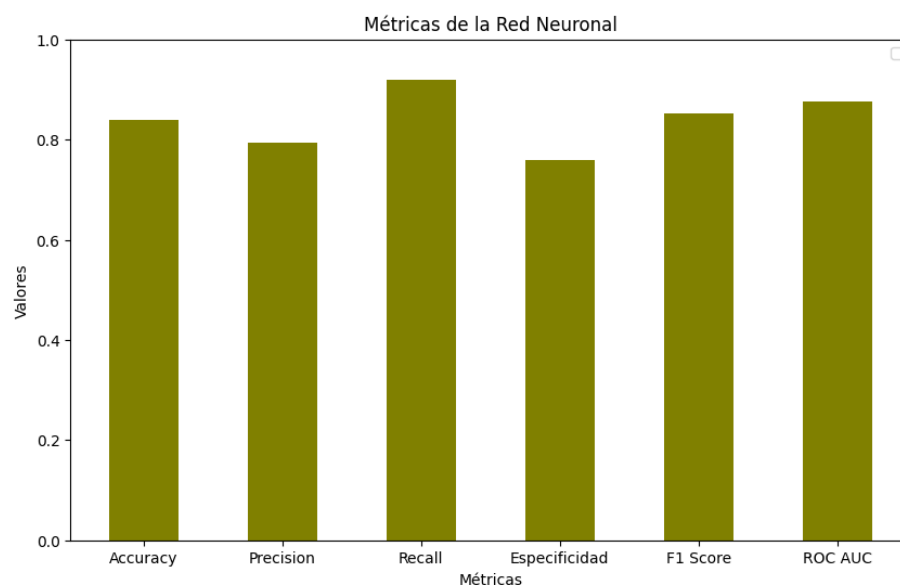
#### 5.4. Elección del Modelo

Se eligió la red neuronal artificial con undersampling sin validación cruzada como el modelo final, ya que obtuvo las mejores métricas en comparación con las otras configuraciones evaluadas.

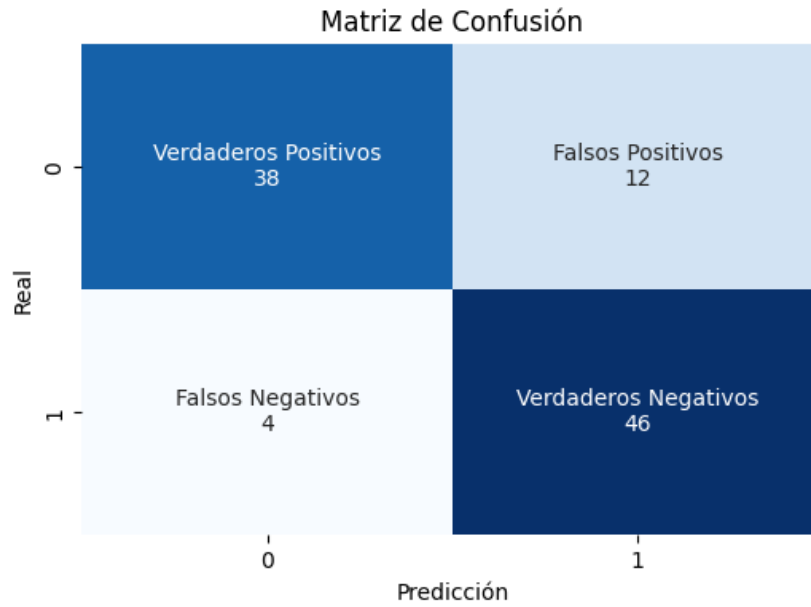
Este enfoque demostró un equilibrio óptimo entre accuracy, precisión, recall, especificidad, F1-Score y ROC-AUC, evidenciando su capacidad para manejar el conjunto de datos balanceado de manera eficaz.

A continuación, en la Figura 5.1. se presentan gráficos detallados que ilustran las métricas obtenidas por este modelo, así como, en la Figura 5.3., el gráfico de la curva ROC-AUC. Además, se incluye la matriz de confusión, ilustrada en la Figura 5.2. que ofrece una representación clara de las predicciones correctas e incorrectas realizadas por el modelo, facilitando una comprensión completa de su rendimiento.

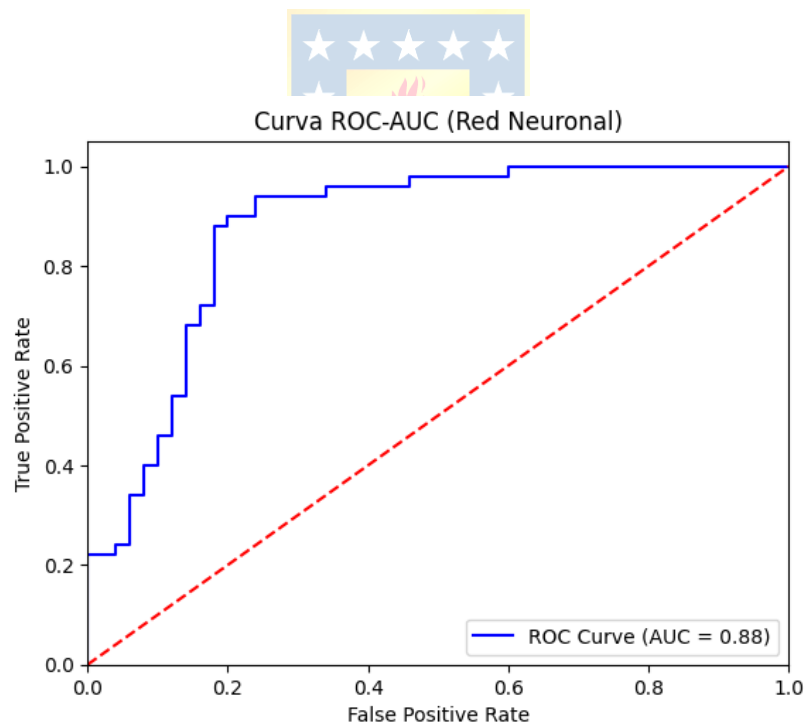
Por otra parte, también se graficó la pérdida de entrenamiento y validación por épocas mostrado en la Figura 5.4, con el fin de asegurar que el modelo elegido no esté sobre ajustado.



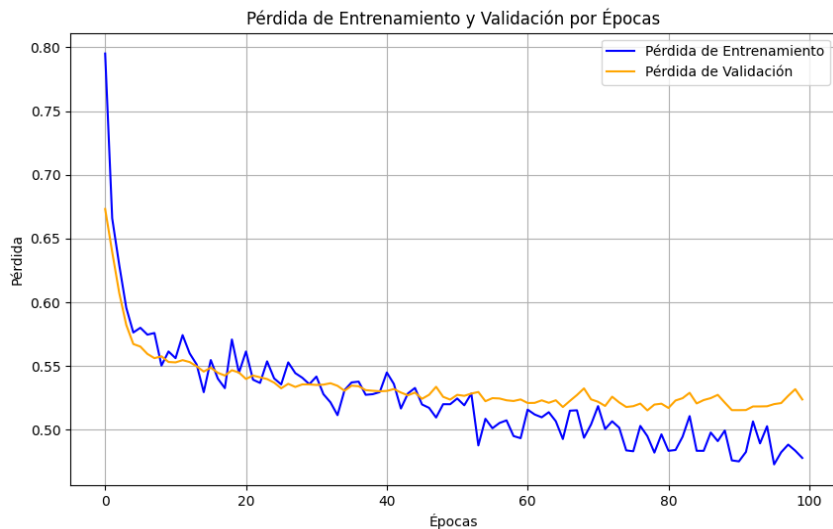
**Figura 5.1. Métricas ANN**



**Figura 5.2. Matriz de Confusión ANN**



**Figura 5.3. Curva ROC-AUC ANN**



**Figura 5.4. Gráfico de Pérdida en Entrenamiento y Validación por Épocas**

## 5.5. Implementación del modelo

Luego de seleccionar el modelo ANN como el de mejor rendimiento, este fue implementado en la aplicación desarrollada, llamada “Estimador Riesgo ACV”, mostrada en la Figura 5.5.

La imagen muestra la interfaz de usuario de la aplicación móvil "Estimador Riesgo ACV". El formulario principal contiene los siguientes campos:

- Edad: campo de texto.
- IMC: campo de texto.
- Nivel de Glucosa: campo de texto.
- Género: selección por radio botones (Hombre, Mujer, Otro).
- Hipertensión: selección por radio botones (Sí, No).
- Enfermedad Cardíaca: selección por radio botones (Sí, No).
- ¿Ha Estado Casado?: selección por radio botones (Sí, No).
- Tipo de Trabajo: menú desplegable.
- Niño: menú desplegable.

Además, hay un formulario secundario a la derecha con:

- Tipo de Residencia: selección por radio botones (Rural, Urbana).
- Estado de Fumador: menú desplegable con la opción "Fumador" seleccionada.
- Botón "CALCULAR" para ejecutar el modelo.

**Figura 5.5. Aplicación Móvil “Estimación Riesgo ACV”**

En la Tabla 5.4 se presentan algunos ejemplos de funcionamiento de la aplicación, ilustrando cómo se procesan distintos perfiles de usuario y los resultados obtenidos en cada caso.

**Tabla 5.4. Ejemplos de Entrada y Resultado del Estimador de Riesgo ACV**

Variable	Ejemplo			
	1	2	3	4
Edad (años)	10	24	45	65
BMI	22	22	28	30
Nivel de glucosa (mg/dL)	120	120	80	160
Género	Hombre	Mujer	Hombre	Mujer
Hipertensión	No	No	Si	Si
Enfermedad cardiaca	No	No	No	Si
¿Ha estado casado?	No	No	Si	No
Tipo de trabajo	Niño	Nunca ha trabajado	Privado	Gubernamental
Tipo de residencia	Rural	Urbana	Urbana	Rural
Estado de fumador	Nunca ha fumado	Fumador	Dejó de fumar	Fumador
Probabilidad de sufrir un ACV	<b>0.26%</b>	<b>3.28%</b>	<b>45.01%</b>	<b>81.35%</b>

Fuente: Elaboración propia

## Capítulo 6. Conclusiones

---

### 6.1. Conclusiones

En conclusión, el modelo de ANN con undersampling demostró ser la mejor opción para el objetivo de este proyecto, dado que sus métricas de evaluación resultaron adecuadas para la predicción de accidentes cerebrovasculares. Aunque las métricas obtenidas, especialmente recall y especificidad, revelan que el modelo es más eficaz para identificar correctamente los casos de riesgo (verdaderos positivos) que para descartarlos (verdaderos negativos). El recall, que mide los verdaderos positivos, superó a la especificidad, lo que hace que el modelo sea más confiable para la detección de posibles ACV.

Además, en un contexto de salud, contar con un recall alto es especialmente relevante, ya que permite identificar el mayor número posible de casos de riesgo, cumpliendo con el objetivo de prevención temprana. En esta aplicación, se prioriza el recall sobre la especificidad, lo cual es esencial para una herramienta que busca alertar a los usuarios sobre riesgos significativos de ACV, aun si esto significa una ligera disminución en la capacidad para descartar casos de bajo riesgo.

Además, el gráfico de pérdida de entrenamiento y validación muestra que el modelo no presenta sobreajuste, lo cual indica una buena capacidad de generalización en nuevos datos. A pesar del desbalance de clases en el conjunto de datos y las técnicas implementadas para corregirlo, como SMOTE y undersampling, las métricas obtenidas son satisfactorias y adecuadas para los propósitos de esta aplicación, que busca ofrecer una estimación de riesgo accesible y confiable.

Es importante reconocer que las limitaciones del conjunto de datos, como el desbalance de clases y la falta de datos más específicos sobre factores de riesgo, pueden restringir el alcance predictivo del modelo en casos específicos. No obstante, gracias a los resultados obtenidos y a las pruebas realizadas en la aplicación "Estimador Riesgo ACV", se puede concluir que esta cumple con su propósito de estimar el riesgo de padecer un ACV, ofreciendo un rendimiento sólido ayudando a la prevención y al monitoreo personal.

### 6.2. Trabajo a Futuro

Este proyecto presenta un gran potencial para la estimación del riesgo de sufrir un accidente cerebrovascular, brindando una herramienta accesible y útil para la prevención y monitoreo personal de la salud. Para mejorar la calidad del modelo y, en consecuencia, la precisión de sus predicciones sería ideal obtener más datos de pacientes que incluyan un mayor número de factores de riesgo. Esto

permitiría hacer la predicción más específica y fiable, ajustándose mejor a distintos perfiles de riesgo y brindando información más personalizada.

Además, se requiere realizar una validación más extendida con un set de datos clínico de mayor tamaño y con la supervisión de un experto en el área de salud. Esta evaluación podría generar respuestas sobre el rendimiento de las predicciones en niveles clínicos de baja, mediana y alta probabilidad de sufrir un ACV. Este paso permitiría comprobar la efectividad del modelo en un entorno más clínico, optimizando su precisión y adecuación en la práctica médica.



## Capítulo 7. Glosario

---

ACC	: Accuracy
ACV	: Accidente Cerebrovascular
ANN	: Artificial Neural Network
AUC	: Area Under Curve
AVAD	: Años de Vida Ajustados por Discapacidad
BMI	: Índice de Masa Corporal
DL	: Deep Learning
DT	: Decision Tree
FPR	: Falso Positivo (False Positive Ratio)
FNR	: Falso Negativo (False Negative Ratio)
IA	: Inteligencia Artificial
LE	: Label Encoder
ML	: Machine Learning
MT	: Memoria de Título
OE	: Ordinal Encoder
OMS:	: Organización Mundial de la Salud
PET	: Tomografía por Emisión de Positrones (Positron Emission Tomography)
PIB	: Producto Interno Bruto
RF	: Random Forest
RL	: Regresión Logística
ROC	: Receiver Operating Characteristic
SMOTE	: Synthetic Minority Over-Sampling Technique
SVM	: Support Vector Machine
TPR	: Verdadero Positivo (True Positive Ratio)
TNR	: Verdadero Negativo (True Negative Ratio)
WSO	: World Stroke Organization



## Capítulo 8. Referencias

---

- [1] “WHO EMRO | Stroke, Cerebrovascular accident | Health topics”. Accedido: 19 de octubre de 2024. [En línea]. Disponible en: <https://www.emro.who.int/health-topics/stroke-cerebrovascular-accident/index.html>
- [2] “Effects of Stroke | American Stroke Association”. Accedido: 19 de octubre de 2024. [En línea]. Disponible en: <https://www.stroke.org/en/about-stroke/effects-of-stroke>
- [3] “ACV: la atención temprana y el tratamiento urgente son las claves para evitar la discapacidad y la muerte - Infobae”. Accedido: 19 de octubre de 2024. [En línea]. Disponible en: <https://www.infobae.com/america/ciencia-america/2021/10/29/acv-la-atencion-temprana-y-el-tratamiento-urgente-son-las-claves-para-evitar-la-discapacidad-y-la-muerte/>
- [4] S. Mainali, M. E. Darsie, y K. S. Smetana, “Machine Learning in Action: Stroke Diagnosis and Outcome Prediction”, *Front Neurol*, vol. 12, dic. 2021, doi: 10.3389/FNEUR.2021.734345.
- [5] V. L. Feigin *et al.*, “World Stroke Organization (WSO): Global Stroke Fact Sheet 2022”, *Int J Stroke*, vol. 17, n° 1, pp. 18–29, ene. 2022, doi: 10.1177/17474930211065917.
- [6] F. Jiang *et al.*, “Artificial intelligence in healthcare: past, present and future”, *Stroke Vasc Neurol*, vol. 2, n° 4, pp. 230–243, dic. 2017, doi: 10.1136/SVN-2017-000101.
- [7] H. Saber, M. Somai, G. B. Rajah, F. Scalzo, y D. S. Liebeskind, “Predictive analytics and machine learning in stroke and neurovascular medicine”, *Neurol Res*, vol. 41, n° 8, pp. 681–690, ago. 2019, doi: 10.1080/01616412.2019.1609159.
- [8] “About Stroke | Stroke | CDC”. Accedido: 20 de octubre de 2024. [En línea]. Disponible en: <https://www.cdc.gov/stroke/about/index.html>
- [9] “Stroke: What It Is, Causes, Symptoms, Treatment & Types”. Accedido: 19 de octubre de 2024. [En línea]. Disponible en: <https://my.clevelandclinic.org/health/diseases/5601-stroke>
- [10] “Ischemic Stroke (Clots) | American Stroke Association”. Accedido: 19 de octubre de 2024. [En línea]. Disponible en: <https://www.stroke.org/en/about-stroke/types-of-stroke/ischemic-stroke-clots>
- [11] “Atherosclerosis | Arterioesclerosis | MedlinePlus en español”. Accedido: 19 de octubre de 2024. [En línea]. Disponible en: <https://medlineplus.gov/spanish/atherosclerosis.html>
- [12] K. Shibata, T. Hashimoto, T. Miyazaki, A. Miyazaki, y K. Nobe, “Thrombolytic Therapy for Acute Ischemic Stroke: Past and Future”, *Curr Pharm Des*, vol. 25, n° 3, pp. 242–250, mar. 2019, doi: 10.2174/1381612825666190319115018.

- [13] “Hemorrhagic Stroke | American Stroke Association”. Accedido: 19 de octubre de 2024. [En línea]. Disponible en: <https://www.stroke.org/en/about-stroke/types-of-stroke/hemorrhagic-strokes-bleeds>
- [14] A. K. A. Unnithan, J. M. Das, y P. Mehta, “Hemorrhagic Stroke”, *StatPearls*, may 2023, Accedido: 19 de octubre de 2024. [En línea]. Disponible en: <https://www.ncbi.nlm.nih.gov/books/NBK559173/>
- [15] “Factores de riesgo accidente cerebrovascular: MedlinePlus enciclopedia médica”. Accedido: 19 de octubre de 2024. [En línea]. Disponible en: <https://medlineplus.gov/spanish/ency/patientinstructions/000341.htm>
- [16] “Machine Learning, revised and updated edition - Ethem Alpaydin - Google Libros”. Accedido: 19 de octubre de 2024. [En línea]. Disponible en: [https://books.google.cl/books?hl=es&lr=&id=2nQJEAQAQBAJ&oi=fnd&pg=PR7&dq=what+is+machine+learning&ots=fI-bT8WFnu&sig=iKjNbLhweaeQWzTkgQi7odzrCwQ&redir\\_esc=y#v=onepage&q=what%20is%20machine%20learning&f=false](https://books.google.cl/books?hl=es&lr=&id=2nQJEAQAQBAJ&oi=fnd&pg=PR7&dq=what+is+machine+learning&ots=fI-bT8WFnu&sig=iKjNbLhweaeQWzTkgQi7odzrCwQ&redir_esc=y#v=onepage&q=what%20is%20machine%20learning&f=false)
- [17] M. Unger, “Data acquisition and the implications of machine learning in the development of a Clinical Decision Support system”, *Proceedings - 2021 IEEE/ACM 1st Workshop on AI Engineering - Software Engineering for AI, WAIN 2021*, pp. 101–104, may 2021, doi: 10.1109/WAIN52551.2021.00022.
- [18] V. Pedrero *et al.*, “Generalidades del Machine Learning y su aplicación en la gestión sanitaria en Servicios de Urgencia”, *Rev Med Chil*, vol. 149, n° 2, pp. 248–254, feb. 2021, doi: 10.4067/S0034-98872021000200248.
- [19] H. Kaur, H. S. Pannu, y A. K. Malhi, “A systematic review on imbalanced data challenges in machine learning: Applications and solutions”, *ACM Comput Surv*, vol. 52, n° 4, jul. 2019, doi: 10.1145/3343440.
- [20] D. Elreedy y A. F. Atiya, “A Comprehensive Analysis of Synthetic Minority Oversampling Technique (SMOTE) for handling class imbalance”, *Inf Sci (N Y)*, vol. 505, pp. 32–64, dic. 2019, doi: 10.1016/J.INS.2019.07.070.
- [21] “Feature Selection in Machine Learning”. Accedido: 19 de octubre de 2024. [En línea]. Disponible en: <https://www.analyticsvidhya.com/blog/2020/10/feature-selection-techniques-in-machine-learning/>

- [22] A. Bommert, X. Sun, B. Bischl, J. Rahnenführer, y M. Lang, “Benchmark for filter methods for feature selection in high-dimensional classification data”, *Comput Stat Data Anal*, vol. 143, p. 106839, mar. 2020, doi: 10.1016/J.CSDA.2019.106839.
- [23] M. Saarela y S. Jauhiainen, “Comparison of feature importance measures as explanations for classification models”, *SN Appl Sci*, vol. 3, n° 2, pp. 1–12, feb. 2021, doi: 10.1007/S42452-021-04148-9/TABLES/4.
- [24] A. M. Alsaqr, “Remarks on the Use of Pearson’s and Spearman’s Correlation Coefficients in Assessing Relationships in Ophthalmic Data”, *African Vision and Eye Health*, vol. 80, n° 1, pp. 1–10, 2021, doi: 10.4102/AVEH.V80I1.612.
- [25] “Machine Learning Algorithms - Javatpoint”. Accedido: 20 de octubre de 2024. [En línea]. Disponible en: <https://www.javatpoint.com/machine-learning-algorithms>
- [26] D. Berrar, “Cross-validation 1”.
- [27] “Métricas De Evaluación De Modelos En El Aprendizaje Automático”. Accedido: 20 de octubre de 2024. [En línea]. Disponible en: <https://www.datasource.ai/es/data-science-articles/metricas-de-evaluacion-de-modelos-en-el-aprendizaje-automatico>
- [28] B. J. Erickson y F. Kitamura, “Magician’s corner: 9. performance metrics for machine learning models”, *Radiol Artif Intell*, vol. 3, n° 3, may 2021, doi: 10.1148/RYAI.2021200126/ASSET/IMAGES/LARGE/RYAI.2021200126.FIG6.JPEG.
- [29] S. Narkhede, “AUC”, jun. 2018.
- [30] E. P. Llumiquinga Almeida, “Estudio comparativo de los algoritmos de clasificación supervisada empleando datos artificiales.”, feb. 2022, Accedido: 20 de octubre de 2024. [En línea]. Disponible en: <http://bibdigital.epn.edu.ec/handle/15000/22184>
- [31] “SVC — scikit-learn 1.6.dev0 documentation”. Accedido: 20 de octubre de 2024. [En línea]. Disponible en: <https://scikit-learn.org/dev/modules/generated/sklearn.svm.SVC.html>
- [32] S. Arik y T. Pfister, “TabNet: Attentive Interpretable Tabular Learning”, *35th AAAI Conference on Artificial Intelligence, AAAI 2021*, vol. 8A, pp. 6679–6687, ago. 2019, doi: 10.1609/aaai.v35i8.16826.
- [33] A. Krogh, “What are artificial neural networks?”, *Nature Biotechnology 2008 26:2*, vol. 26, n° 2, pp. 195–197, feb. 2008, doi: 10.1038/nbt1386.
- [34] M. Chen, U. Challita, W. Saad, C. Yin, y M. Debbah, “Artificial Neural Networks-Based Machine Learning for Wireless Networks: A Tutorial”, *IEEE Communications Surveys and Tutorials*, vol. 21, n° 4, pp. 3039–3071, oct. 2019, doi: 10.1109/COMST.2019.2926625.

- [35] M. G. M. Abdolrasol *et al.*, “Artificial Neural Networks Based Optimization Techniques: A Review”, *Electronics 2021, Vol. 10, Page 2689*, vol. 10, n° 21, p. 2689, nov. 2021, doi: 10.3390/ELECTRONICS10212689.
- [36] “Introducción a Android Studio | Android Developers”. Accedido: 20 de octubre de 2024. [En línea]. Disponible en: <https://developer.android.com/studio/intro?hl=es-419>
- [37] B. Akter, A. Rajbongshi, S. Sazzad, R. Shakil, J. Biswas, y U. Sara, “A Machine Learning Approach to Detect the Brain Stroke Disease”, *Proceedings - 4th International Conference on Smart Systems and Inventive Technology, ICSSIT 2022*, pp. 897–901, 2022, doi: 10.1109/ICSSIT53264.2022.9716345.
- [38] S. Rahman, M. Hasan, y A. K. Sarkar, “Prediction of Brain Stroke using Machine Learning Algorithms and Deep Neural Network Techniques”, *European Journal of Electrical Engineering and Computer Science*, vol. 7, n° 1, pp. 23–30, ene. 2023, doi: 10.24018/EJECE.2023.7.1.483.
- [39] E. Dritsas y M. Trigka, “Stroke Risk Prediction with Machine Learning Techniques”, *Sensors (Basel)*, vol. 22, n° 13, p. 4670, jul. 2022, doi: 10.3390/S22134670.
- [40] V. Krishna, J. Sasi Kiran, P. Prasada Rao, G. Charles Babu, y G. John Babu, “Early Detection of Brain Stroke using Machine Learning Techniques”, *Proceedings - 2nd International Conference on Smart Electronics and Communication, ICOSEC 2021*, pp. 1489–1495, 2021, doi: 10.1109/ICOSEC51865.2021.9591840.
- [41] K. McDonnell, F. Murphy, B. Sheehan, L. Masello, y G. Castignani, “Deep learning in insurance: Accuracy and model interpretability using TabNet”, *Expert Syst Appl*, vol. 217, may 2023, doi: 10.1016/j.eswa.2023.119543.
- [42] C. Shah, Q. Du, y Y. Xu, “Enhanced TabNet: Attentive Interpretable Tabular Learning for Hyperspectral Image Classification”, *Remote Sens (Basel)*, vol. 14, n° 3, feb. 2022, doi: 10.3390/rs14030716.
- [43] V. R. Contreras Valderrama, “IMPLEMENTACIÓN DE ALGORITMOS DE IA PARA LA DETECCIÓN DE FRAUDE EN SERVICIOS DE SALUD”, Concepción, mar. 2024.
- [44] M. Senbekov *et al.*, “The recent progress and applications of digital technologies in healthcare: A review”, 2020, *Hindawi Limited*. doi: 10.1155/2020/8830200.
- [45] A. Barragán-Montero *et al.*, “Artificial intelligence and machine learning for medical imaging: A technology review”, 1 de marzo de 2021, *Associazione Italiana di Fisica Medica*. doi: 10.1016/j.ejmp.2021.04.016.

- [46] I. Sim, “Mobile Devices and Health”, *New England Journal of Medicine*, vol. 381, nº 10, pp. 956–968, sep. 2019, doi: 10.1056/nejmra1806949.
- [47] M. Karatas, L. Eriskin, M. Deveci, D. Pamucar, y H. Garg, “Big Data for Healthcare Industry 4.0: Applications, challenges and future perspectives”, 15 de agosto de 2022, *Elsevier Ltd.* doi: 10.1016/j.eswa.2022.116912.
- [48] “Kaggle: Your Machine Learning and Data Science Community”. Accedido: 29 de octubre de 2024. [En línea]. Disponible en: <https://www.kaggle.com/>
- [49] M. S. Pathan, Z. Jianbiao, D. John, A. Nag, y S. Dev, “Identifying Stroke Indicators Using Rough Sets”, *IEEE Access*, vol. 8, pp. 210318–210327, 2020, doi: 10.1109/ACCESS.2020.3039439.



## UNIVERSIDAD DE CONCEPCION – FACULTAD DE INGENIERIA

### RESUMEN DE MEMORIA DE TITULO

**Departamento** : Departamento de Ingeniería Eléctrica  
**Carrera** : Ingeniería Civil Biomédica  
**Nombre del memorista** : Matías Ignacio Bucarey Echeverría  
**Título de la memoria** : APLICACIÓN MÓVIL PARA LA ESTIMACIÓN DE RIESGO DE ACCIDENTE CEREBROVASCULARES BASADO EN APRENDIZAJE AUTOMÁTICO

**Fecha de la presentación oral:**

**Profesor(es) Guía** : Rosa Figueroa Iturrieta  
**Profesor(es) Revisor(es)** : Esteban Pino Q. y Gerónimo Bolado L.  
**Concepto** :  
**Calificación** :

#### **Resumen**

La presente memoria de título se enfoca en el desarrollo de una aplicación móvil para la estimación del riesgo de accidente cerebrovascular (ACV) utilizando modelos de Machine Learning (ML). La incidencia de ACV es una problemática significativa a nivel mundial, dada su alta tasa de mortalidad y las secuelas que provoca en los sobrevivientes. Por ello, una herramienta de evaluación temprana y accesible es fundamental para facilitar la prevención y el monitoreo de esta afección.

La aplicación, desarrollada en Android Studio y basada en el modelo de Red Neuronal Artificial (ANN), permite al usuario ingresar datos personales y recibir una estimación probabilística sobre su riesgo de sufrir un ACV. La elección del modelo ANN, junto con la integración de métodos como el undersampling para el balance de clases, demostró ser la opción más efectiva para alcanzar resultados confiables y específicos en el contexto del conjunto de datos disponible. A pesar del desbalance de clases y otras limitaciones de los datos, el modelo mostró una capacidad adecuada para detectar posibles casos de riesgo, priorizando el recall sobre la especificidad, aspecto clave en aplicaciones de salud donde es preferible minimizar los falsos negativos.

La aplicación fue evaluada mediante múltiples métricas (accuracy, precisión, recall, especificidad, F1-score y AUC-ROC), y los resultados demostraron un buen desempeño, sin sobreajuste, según lo indicado por los gráficos de pérdida de entrenamiento y validación. Esto confirma la consistencia del modelo y su adecuación para estimar el riesgo de ACV en distintos perfiles de usuario.

Entre las conclusiones de este proyecto, se destaca que el modelo de red neuronal artificial implementado en la aplicación cumple satisfactoriamente su propósito de estimar el riesgo de accidente cerebrovascular, proporcionando resultados confiables y específicos basados en los datos ingresados por el usuario. La herramienta es particularmente útil para la predicción temprana de riesgos de ACV, priorizando el recall en la identificación de casos de riesgo, lo cual es crucial en el ámbito de la salud.