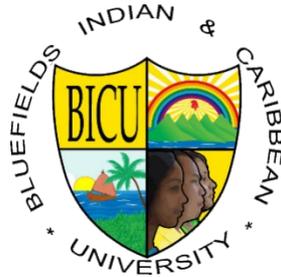


**BLUEFIELDS INDIAN & CARIBBEAN UNIVERSITY  
BICU**



**CIENCIA Y TECNOLOGÍA  
DIRECCIÓN ESPECÍFICA DE INFORMÁTICA**

**INFORME FINAL DE INVESTIGACIÓN INSTITUCIONAL**

**Modelo basado en aprendizaje automático de estimación de riesgo de mortalidad en pacientes con trauma craneoencefálico para la Región Autónoma Costa Caribe Sur de Nicaragua**

**Autores:**

Dexon Mckensy Sambola <sup>1</sup>

Kerry Kenton Kelly Kandler <sup>2</sup>

Deyvon Kestner Ordoñez Cuthbert <sup>3</sup>

Jacqueline Georgina Kerr Taylor <sup>4</sup>

Emely de los Ángeles Urroz Cruz<sup>5</sup>

Shanely Tatiana Martinez Cuthbert<sup>6</sup>

Bluefields, RACCS, Nicaragua  
Mayo, 2024

***“La Educación es la Mejor Opción para el Desarrollo de los Pueblos”***

---

<sup>1</sup> Dirección específica de Informática, Bluefields Indian & Caribbean University (BICU), Bluefields 81000, Nicaragua; dexon.sambola@bicu.edu.ni

<sup>2</sup> Dirección específica de Informática, Bluefields Indian & Caribbean University (BICU), Bluefields 81000, Nicaragua; kerry.kelly@bicu.edu.ni

<sup>3</sup> Área de gestión tecnológica, Bluefields Indian & Caribbean University (BICU), Bluefields 81000, Nicaragua; deyvon.ordonez@bicu.edu.ni

<sup>4</sup> Dirección específica de Informática, Bluefields Indian & Caribbean University (BICU), Bluefields 81000, Nicaragua; jacqueline.kerr@bicu.edu.ni

<sup>5</sup> Tesista de Ingeniería en Sistemas de Información, Bluefields Indian & Caribbean University (BICU), Bluefields 81000, Nicaragua; emely.urroz@es.bicu.edu.ni

<sup>6</sup> Tesista de Ingeniería en Sistemas de Información, Bluefields Indian & Caribbean University (BICU), Bluefields 81000, Nicaragua; tatiana.martinez@es.bicu.edu.ni

## ÍNDICE DE CONTENIDO

<b>RESUMEN</b>	<b>iv</b>
<b>ABSTRACT</b>	<b>v</b>
<b>I. INFORMACIÓN GENERAL</b>	<b>1</b>
1.1. Recepción y resolución	1
1.2. Objetivo de desarrollo sostenible (ODS)	1
1.3. Datos generales del investigador principal	1
1.4. Identificación del Proyecto de Investigación	2
<b>II. INTRODUCCIÓN</b>	<b>3</b>
2.1. Antecedes y contexto del Problema	3
2.2. Pregunta de Investigación	4
2.3. Objetivos	4
a) General	4
b) Específicos	4
2.4. Justificación	4
2.5. Limitaciones y riesgos	5
2.6. Hipótesis	6
<b>III. MARCO TEÓRICO</b>	<b>7</b>
3.1. Estado del arte	7
3.2. Teorías y conceptos asumidos	12
<b>IV. DISEÑO METODOLÓGICO</b>	<b>16</b>
4.1. Área de localización del estudio	16
4.2. Tipo de estudio según el enfoque, amplitud o periodo	16
4.3. Población y muestra	16
4.3.1. Población	16
4.3.2. Tipo de muestra y muestreo	16
4.3.3. Técnica e instrumento de la investigación.	16
4.4. Diseño Experimental	17
4.4.1. Técnica de Recolección de Datos	17
4.4.2. Confiabilidad y validez de los instrumentos	17
4.5. Operacionalización de la variable	17
4.6. Análisis de datos	18
4.7. Metodología de desarrollo	20
<b>V. RESULTADOS Y DISCUSIÓN</b>	<b>22</b>
<b>VI. CONCLUSIONES</b>	<b>28</b>
<b>VII. RECOMENDACIONES</b>	<b>29</b>



**VIII. REFERENCIAS**

30

**IX. ANEXOS**

1

## ÍNDICE DE TABLAS

<b>Tabla 1.</b> Métodos y técnicas destacados en el estado del arte .....	10
<b>Tabla 2.</b> Clasificación de PA .....	13
<b>Tabla 3.</b> Frecuencia respiratoria por edad.....	14
<b>Tabla 4.</b> Técnicas e instrumentos de la investigación.....	16
<b>Tabla 5.</b> Operacionalización de variables.....	17
<b>Tabla 6.</b> Métricas utilizadas para definir el modelo con el mejor rendimiento .....	21
<b>Tabla 7.</b> Métricas de precisión, sensibilidad y especificidad.....	23

## INDICE DE FIGURAS

<b>Figura 1.</b> Cantidad de artículos relacionados con AA aplicado a la medicina, publicados entre 2000 y 2019 .....	8
<b>Figura 2.</b> Métricas de la curva ROC .....	23
<b>Figura 3.</b> Utilidad del modelo como apoyo para la atención y seguimiento de pacientes con TCE – Hospital Ethel Kandler (Corn Island).....	24
<b>Figura 4.</b> Interfaz amigable – Hospital Ethel Kandler (Corn Island) .....	24
<b>Figura 5.</b> El modelo mejoraría la atención a pacientes con TCE – Hospital Ethel Kandler (Corn Island).....	25
<b>Figura 6.</b> Contribuye al desarrollo tecnológico del municipio – Hospital Ethel Kandler (Corn Island).....	25
<b>Figura 7.</b> Utilidad del modelo como apoyo para la atención y seguimiento de pacientes con TCE – Centro de Salud Perla María Norori (Laguna de Perlas) .....	26
<b>Figura 8.</b> Interfaz amigable – Centro de Salud Perla María Norori (Laguna de Perlas).....	26
<b>Figura 9.</b> El modelo mejoraría la atención a pacientes con TCE – Centro de Salud Perla María Norori (Laguna de Perlas).....	26
<b>Figura 10.</b> Contribuye al desarrollo tecnológico del municipio – Centro de Salud Perla María Norori (Laguna de Perlas).....	27

## RESUMEN

La Inteligencia Artificial (IA) y la medicina han encontrado varios puntos en los que convergen, cambiando el concepto de salud. Entre los problemas de atención inmediata se encuentran los traumas craneoencefálicos, que constituyen un importante problema de salud pública en todos los países, cada día en el mundo, alrededor de 16.000 personas mueren por traumatismos. Este estudio tiene como objetivo desarrollar un modelo basado en ML para estimar la probabilidad de riesgo de mortalidad en pacientes con TCE. El proyecto se desarrolló en la Región Autónoma de la Costa Caribe Sur, centrándose en 3 unidades de salud, Hospital Regional Ernesto Sequeira Blanco (Bluefields), Hospital Ethel Kandler (Corn Island) y el Centro de Salud Perla María Norori (Laguna de Perlas), bajo la metodología SCRUM, la cual permitió la retroalimentación continua del modelo propuesto, los algoritmos de ML seleccionados para la construcción del modelo fueron la regresión logística, árbol de decisión, Random Forest y K-NN, el conjunto de datos para el modelo inicial fue el CRASH-2, todo el análisis y procesamiento se realizó en Python. Se ha demostrado que el modelo es capaz de predecir con una precisión aceptable la probabilidad de mortalidad en pacientes con TCE, sin embargo, Random Forest tuvo un mejor desempeño; en promedio tuvo una efectividad del 87,06%, mientras que la regresión logística, árbol de decisión y K-NN fueron del 75.03%, 86.48% y 77,87% respectivamente. Los resultados fueron prometedores, y el estudio ofrece una perspectiva alentadora para el desarrollo de futuros modelos de predicción basados en Aprendizaje Automático. Es importante destacar que este modelo es complementario a la toma de decisiones clínicas y no debe reemplazar el juicio clínico.

**Palabras claves:** Algoritmos de aprendizaje supervisado; Lesión cerebral; Predictores.

## ABSTRACT

Artificial Intelligence and medicine have found various points where they converge, changing the concept of health. Among the problems of immediate attention are Traumatic Brain Injury (TBI), which constitute an important public health problem in all countries, every day in the world, about 16,000 people die from trauma. This study aims to develop a Machine Learning-based model to estimate the probability of mortality risk in patients with TBI. The project was developed in the Autonomous Region of the Southern Caribbean Coast, focusing on three health units, Ernesto Sequeira Blanco Regional Hospital (Bluefields, Ethel Kandler Hospital (Corn Island) and the Perla María Norori Health Center (Pearl Lagoon), under the SCRUM methodology, which allowed continuous feedback of the proposed model, the Machine Learning algorithms selected for the construction of the model were Logistic Regression, Decision Tree, Random Forest and K-NN, the dataset for the initial model was the CRASH-2, all analysis and processing were done in Python. The model has been shown to be able to predict with acceptable accuracy the probability of mortality in patients with TBI, however, Random Forest performed better; on average it was 87.06% effective, while the Logistic Regression, Decision Tree and K-NN were 75.03%, 86.48% and 77.87% respectively. The results were promising, and the study offers an encouraging prospect for the development of future ML-based prediction models. Importantly, this model is complementary to clinical decision-making and should not replace clinical judgment.

**Key Words:** Brain injury; Supervised learning algorithms; Predictors.

## I. INFORMACIÓN GENERAL

### 1.1.Recepción y resolución

#### Uso interno de la Dirección de Investigación y Postgrado

Fecha de recepción	Resolución	Fecha de resolución	Inicio del proyecto
--------------------	------------	---------------------	---------------------

### 1.2.Objetivo de desarrollo sostenible (ODS)

Objetivo de desarrollo Sostenible (ODS)	Objetivo 3: Garantizar una vida sana y promover el bienestar para todos en todas las edades.
Meta del ODS	3.6 Reducir a la mitad el número de muertes y lesiones causadas por accidentes de tráfico en el mundo.
Indicador	3.6.1 Tasa de mortalidad por lesiones debidas a accidentes de tráfico.

La Agenda 2030 y los Objetivos de Desarrollo Sostenible, Organización de las Naciones Unida

[Dar Click para Descarga](#)

### 1.3.Datos generales del investigador principal

#### Datos Generales del Investigador Principal

Dexon Mckensy Sambola

Dirección Específica de Informática

85360819

dexon.sambola@bicu.edu.ni

<https://orcid.org/0000-0002-3121-0831>

Formación Académica:

- Máster en Nueva Tecnologías en Informática, con Especialidad en Tecnologías Inteligentes y del Conocimiento con Aplicaciones en Medicina, por la universidad de Murcia.
- Ingeniero en sistemas, por la universidad BICU.
- Diplomado en innovación empresarial, por la universidad de Guadalajara.
- IT Project Management by Indian School of Business

### 1.4. Identificación del Proyecto de Investigación

**Título del Proyecto de Investigación:**

Modelo basado en aprendizaje automático de estimación de riesgo de mortalidad en pacientes con trauma craneoencefálico para la Región Autónoma Costa Caribe Sur de Nicaragua

**Fecha de Inicio:** 01 de septiembre 2023      **Fecha de Finalización:** 29 de febrero 2024      **Duración (en meses):** 6

Área estratégica de Investigación	Ciencia y Tecnología	<b>X</b>
	Recursos Naturales y medio Ambiente	
	Adaptación al cambio climático	
	Seguridad Social y Humana	
	Ciencias Económicas y Administrativas	
	Ciencias de la Educación	
	Ciencias Jurídicas	
	Ciencias de la salud	<b>X</b>
	Tecnología de Información y Comunicación (TIC)	<b>X</b>
Áreas del Conocimiento adoptadas por el Consejo Nacional de Evaluación y Acreditación (CNEA)	Educación	
	Humanidades y arte	
	Ciencias sociales, educación comercial y derecho	
	Ciencias	<b>X</b>
	Ingeniería, industria y construcción	<b>X</b>
	Agricultura	
	Salud y servicios sociales	<b>X</b>
	Servicios	

Línea (s) de Investigación: *(Indique al menos una 1)*

**Sistema de Información Biomédicos**

## II. INTRODUCCIÓN

### 2.1. Antecedes y contexto del Problema

Los traumas craneoencefálicos (TCE) constituyen un importante problema de salud pública en todos los países (Morales Acevedo & Mora García, 1986). Según (Giner et al., 2002) es una de las principales causas de muerte y discapacidad mundial; causa la mayoría de las muertes por traumas, con una tasa de 579 por 100.000 persona/año, principalmente debido a caídas o accidentes vehiculares. Afecta en gran medida a los países tercermundistas, lo cual representa a casi toda Latinoamérica. La incidencia de TCE varía considerablemente dependiendo del país o continente que se estudie, la mortalidad del TCE es mucho más alta en países en desarrollo como Nicaragua, que en países del primer mundo debido a la demora de la atención en servicios de salud (Herrera Martínez et al., 2018).

La Organización Mundial de la Salud (OMS) (2018) prevé que para el año 2030 la TCE supere a otras situaciones como causa de muerte y discapacidad. Representa un importante problema de salud mundial, impacta los sistemas de salud por el tratamiento de los pacientes, las nuevas herramientas diagnósticas, centros de neurocirugía e implica una serie de consecuencias para la calidad de vida del individuo y un gasto considerable para los Estados (Bravo Neira et al., 2019).

El correcto diagnóstico del estado de pacientes con TCE se ha convertido en una problemática de gran impacto en la comunidad médica, debido a la incertidumbre de este proceso al utilizar la Escala de Coma de Glasgow (ECG) como única herramienta para determinar el estado de un paciente, el puntaje se basa en la habilidad del observador, es decir, dos personas pueden puntuar la evaluación de un paciente de manera diferente, especialmente si no están entrenadas. Esto sugiere una problemática, especialmente en la Región Autónoma Costa Caribe Sur (RACCS) dada la poca especialización existente en el área, por lo cual se debe abordar este inconveniente, con la idea de brindar soluciones que propicien resultados más objetivos y certeros a la hora de llevar a cabo la evaluación de pacientes con TCE.

## 2.2. Pregunta de Investigación

¿El modelo será capaz de predecir la mortalidad de pacientes con TCE atendidos en emergencia en hospitales y centros de salud de la RACCS?

## 2.3. Objetivos

### a) General

Desarrollar un modelo predictivo que permita estimar el riesgo de mortalidad en pacientes con TCE para la Región Autónoma Costa Caribe Sur de Nicaragua.

### b) Específicos

1. Identificar los requerimientos necesarios para la construcción del modelo predictivo.
2. Diseñar el modelo predictivo que permita la estimación de riesgo de mortalidad en pacientes con TCE.
3. Construir el modelo de estimación de riesgo de mortalidad en pacientes con TCE de la Región Autónoma Costa Caribe Sur de Nicaragua.
4. Validar el modelo construido, mediante técnicas de correlación.

## 2.4. Justificación

La TCE se define como una lesión estructural y/o alteración fisiológica de la función cerebral inducida por un traumatismo a causa de una fuerza externa, siendo una de las principales causas de morbimortalidad a nivel mundial en pacientes menores de 45 años (Borja Santillán et al., 2021). Clínicamente se clasifica en leve, moderado y severo mediante la ECG (Herrera Martínez et al., 2018) . Según (OPS/OMS, s. f.) cada día en el mundo, cerca de 16,000 personas mueren a causa de traumatismos, estos representan 12% de la carga mundial de morbilidad, la tercera causa más importante de mortalidad general y la principal causa de muerte en el grupo de edades de 1 a 45 años. Aun así, en la mayoría de los países el traumatismo es típicamente considerada como accidente, con poco

esfuerzo comprometido en investigación para el estudio y la reducción de esta enfermedad (Montero, 2012).

Esto presenta un gran problema al cuerpo médico y comunidad sanitaria, quienes deben buscar métodos o alternativas a esta situación que afecta la vida de millones de personas alrededor del mundo. Especialmente en lugares que no cuentan con la instrumentación necesaria para la realización de la Tomografía Axial Computarizada (TAC), cuya falta dificulta el proceso de la correcta diagnosticación de este tipo de pacientes. Con el fin de contrarrestar esta deficiencia en el sistema de salud se propone el desarrollo de un modelo que permita estimar la probabilidad de riesgo de mortalidad en pacientes con TCE de la RACCS de Nicaragua, basado en Aprendizaje Automático (AA), que permita estimar la probabilidad de riesgo de mortalidad en estos pacientes a partir de parámetros clínicos para proporcionar una mejor atención. El proyecto se desarrollará para validar la viabilidad de este modelo en pacientes de la región, como una herramienta de apoyo de toma de decisión.

### 2.5. Limitaciones y riesgos

<b>Limitantes</b>	<b>Acciones para corrección</b>	<b>Medios</b>
Acceso a la base de datos del sistema de salud	Coordinación con el sistema de salud.	BICU/MINSA
Herramientas tecnológicas adecuadas para la construcción del modelo	Gestión de compra	BICU
Acceso limitado al internet institucional	Solicitud de libre acceso al internet institucional	BICU



## 2.6. Hipótesis

El modelo será capaz de predecir la mortalidad de pacientes con TCE atendidos en emergencia a partir de datos clínicos y demográficos.

### III. MARCO TEÓRICO

#### 3.1. Estado del arte

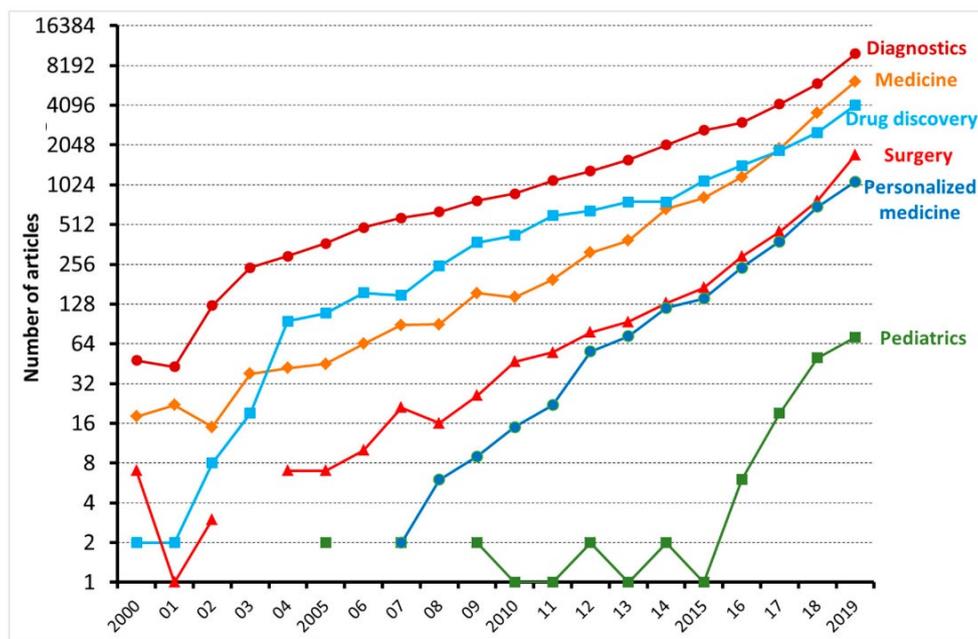
El Machine Learning (ML) o Aprendizaje Automático (AA) es una rama de la Inteligencia Artificial (IA) utilizado con éxito en múltiples áreas. “En los últimos años con la creciente disponibilidad de información clínica almacenada electrónicamente el campo médico se ha convertido en un ambiente ideal para el desarrollo y aplicación de esta tecnología” (Álvarez Vega et al., 2020). En los inicios de la medicina los médicos trabajaban en un ecosistema cerrado, médicos trabajando juntos buscando resolver problemas, actualmente ese modelo no es funcional, la medicina se ha tornado más compleja, se dispone de muchas más terapias, medicamentos, exámenes, y procesar estos datos exceden la capacidad de comprensión de la mente humana (Obermeyer & Lee, 2017). Por tal razón, la necesidad de desarrollar herramientas que sean capaces de asistir a los médicos en los procesos clínicos.

##### 3.1.1. Modelos de predicción clínicos basados en AA

El uso de la AA en el campo medico es amplio, prácticamente se puede aplicar en todas las especialidades médicas. La gran cantidad de datos acumulados en el tiempo brinda el contexto adecuado para desarrollar modelos capaces de hacer predicciones clínicas. Los modelos de predicción clínicos tienen como objetivo predecir los resultados del paciente, para informar el diagnóstico o el pronóstico, cada año se publican cientos de modelos de predicción en la literatura, pero muchos se desarrollan utilizando un conjunto de datos que es demasiado pequeño para el número total de la población de estudio, esto conduce a predicciones inexactas (Riley et al., 2020). Por otro lado, el error más común empleado en predicciones de resultados múltiples es derivar un modelo para cada resultado por separado y luego multiplicar los riesgos pronosticados. En caso de resultados múltiples se recomienda cuatro enfoques; cadena clasificadora probabilística, regresión logística multinomial, regresión logística multivariante y el modelo probit bayesiano (Martin et al., 2021). Los algoritmos de AA involucran diferentes técnicas, en particular las redes

neuronal, los árboles de decisión y las redes bayesianas, teniendo un gran desarrollo e impacto en los modelos de predicciones clínicas (Montero Rodríguez et al., 2019).

Se anticipa que las nuevas tecnologías de IA que integran AA influirán sustancialmente en la atención médica, cada día se está volviendo más relevante en la medicina, AA se enfoca en hacer predicciones precisas, mientras que los modelos estadísticos tradicionales tienen como objetivo inferir relaciones entre variables. “Los beneficios de ML comprenden flexibilidad y escalabilidad en comparación con los enfoques estadísticos convencionales, lo que lo hace útil para varias tareas, como diagnóstico y clasificación, y predicciones de supervivencia” (Rajula et al., 2020). En los últimos años la cantidad de artículos que aplican AA al campo médico ha aumentado exponencialmente.



**Figura 1.** Cantidad de artículos relacionados con AA aplicado a la medicina, publicados entre 2000 y 2019

Fuente: (Rajula et al., 2020).

### 3.1.2. AA para predicción mortalidad de traumas craneoencefálicos.

Se han informado predicciones exitosas utilizando algoritmos de AA en varias áreas de la medicina. Entre estos podemos mencionar: diagnósticos personalizados, predicción de mortalidad por leucemia, predicción de la progresión de la enfermedad de parkinson, predicción de falla viral en pacientes con SIDA, predicción del riesgo de diabetes en

etapas tempranas, predicción de mortalidad perinatal, entre muchos otros. Sin embargo, en esta ocasión el esfuerzo se centra en la aplicación de AA en predicciones de TCE.

Los algoritmos AA aplicado en predicción de mortalidad de TCE son varias, (Matsuo et al., 2020) realizó una comparación de nueve algoritmos: ridge regression, LASSO regression, random forest, gradient boosting, extra trees, decision tree, gaussian naive bayes, multinomial naive bayes y support vector machine. El algoritmo de ridge regression demostró el mejor rendimiento para la predicción de la mortalidad; con casi un 90% de precisión. Las variables más destacadas en estos modelos fueron, la edad, ECG, los productos de degradación de fibrina/fibrinógeno y la glucosa. La limitante más notoria fue la falta de validación externa del algoritmo con mejor resultado.

A diferencia del estudio anterior, en donde compararon algoritmos existentes, (Raj et al., 2019) centraron sus esfuerzos en la creación de dos algoritmos capaces de predecir la mortalidad en tiempo real durante los cuidados intensivos después de una lesión cerebral traumática. Implementaron modelos de regresión logística basados en AA tomando en cuenta la Presión Arterial (PA), Presión de Perfusión Cerebral (PPC) y ECG para predecir la mortalidad a los 30 días. Utilizaron una técnica de validación cruzada estratificada para la validación interna. Tuvieron una precisión de 81% y 84%, pero al igual que el estudio de (Matsuo et al., 2020) este estudio carece de validación externa.

“La incidencia de TCE varía considerablemente dependiendo del país o continente que se estudie, la mortalidad del TCE es mucho más alta en países tercermundista que en países del primer mundo” (Herrera Martínez et al., 2018). Es importante comprender el comportamiento de las variables predictivas en la población de los países de bajos y moderados ingresos (PBMI). Son pocos los intentos de generar modelos de predicción para los resultados de TCE a partir de datos locales en PBMI, he ahí la relevancia del estudio realizado por (Amorim et al., 2020), donde diseñaron y compararon una serie de modelos predictivos de mortalidad en pacientes con TCE en Brasil utilizando AA. Las variables consideradas fueron el sexo, la edad, respuesta pupilar, ECG, presencia de hipoxia e hipotensión, TAC, Frecuencia Respiratoria (FR) y Presión arterial sistólica (PAS), el modelo tuvo un acierto de 22.85% en 14 días. El algoritmo con mejor resultado en esta ocasión fue random forest, cabe destacar que se hizo validación externa.

La información existente sobre los modelos de predicción de mortalidad intrahospitalaria para pacientes con TCE ingresados en los servicios de urgencias son limitadas. Sin embargo, (Hsu et al., 2021) desarrollaron un modelo de predicción, que a partir de medidas clínicas y demográficas sea capaz de estimar la mortalidad de pacientes con TCE ingresados en el servicio de urgencias. Los variables más significativo fueron las ECG, valoración de gravedad de lesiones (ISS), Frecuencia de Ritmo Cardíaco (FRC) y la PAS. En este estudio el algoritmo J48 demostró los mejores resultados con una precisión del 93,2%.

**Tabla 1.** Métodos y técnicas destacados en el estado del arte

Lenguaje	Librerías	Algoritmos	Validación	Variables	Análisis
<b>Machine Learning to Predict In-hospital Morbidity and Mortality after Traumatic Brain Injury Kazuya (Matsuo et al., 2020)</b>					
Python	Scikit-learn	Ridge regression	Five-cross-validation	Edad	Python
		LASSO regression	K-fold cross-validation	ECG	Scikit-learn
		Random forest	Bootstrap	Productos de degradación de fibrina (PDF)	
		Gradient boosting		PAS	
		Extra trees		TAC	
		Decision tree		Glucosa	
		Gaussian naive bayes		Respuesta pupilar	
		Multinomial naive bayes		FR	
		Support vector machine			
		<b>Machine learning-based dynamic mortality prediction after traumatic brain injury (Raj et al., 2019)</b>			
Python	Scikit-learn	ICP-MAP-CPP	Stratified k-fold cross-validation	Edad	SPSS
		ICP-MAP-CPP-GCS		PA	
				ECG	
				PPC	

Lenguaje	Librerías	Algoritmos	Validación	Variables	Análisis
<b>Machine Learning to Predict In-hospital Morbidity and Mortality after Traumatic Brain Injury</b> Kazuya (Matsuo et al., 2020)					
Tiempo					
<b>Prediction of Early TBI Mortality Using a Machine Learning Approach in a LMIC Population</b> (Amorim et al., 2020)					
Python	Scikit-learn	Random forest Discriminant analysis Bayesian methods neural network, Decision tree Gradient boosting Generalized linear model Partial least squares Multivariate adaptive regression splines	Chi-square T-tests Five-cross-validation	Sexo Edad Respuesta pupilar ECG Presencia de hipoxia e hipotensión TAC PAS FR	R
<b>Machine Learning Algorithms to Predict In-Hospital Mortality in Patients with Traumatic Brain Injury</b> (Hsu et al., 2021)					
Python	Scikit-learn	Linear SVC KNeighbors Naive Bayes SVC Ensemble random tree J48 Random forest Reduce error pruning tree K-nearest neighbors Naive Bayes	10-fold cross-validation	Edad Sexo ECG ISS PAS FRC	Weka T tests Python Scikit-learn

Lenguaje	Librerías	Algoritmos	Validación	Variables	Análisis
<b>Machine Learning to Predict In-hospital Morbidity and Mortality after Traumatic Brain Injury Kazuya (Matsuo et al., 2020)</b>					
		Support vector machine			

Es indiscutible que el lenguaje de programación Python destaca en la construcción de modelos predictivo en paciente con TCE. El proceso de desarrollo de modelos de AA generalmente tiene un enfoque cuantitativo, que implica cálculos numéricos y análisis de datos. En este contexto, lo normal es pensar en librerías como Numpy, SciPy, Pandas o Numba, debido a que son las librerías de Python ideales para el análisis de datos y computación numérica. Sin embargo, no son las librerías primarias aplicada a la construcción de estos modelos. Scikit-learn es la primaria, es una librería específicamente para el desarrollo de AA y análisis de datos, está diseñado para interactuar con NumPy, SciPy y Matplotlib; sus principales ventajas son su facilidad de uso y la gran cantidad de técnicas de AA que implementa. La tabla 1 condensa los métodos y técnica que más destacaron en el desarrollo de modelos AA para la predicción de mortalidad en TCE.

### 3.2. Teorías y conceptos asumidos

#### 3.2.1. Región Autónoma Costa Caribe Sur

La Región Autónoma Costa Caribe Sur (RACCS) se ubica al sureste de Nicaragua cubre el 21.1% del territorio nacional conformado por los municipios de Bluefields, Corn Island, Kukra hill, El Ayote, Nueva Guinea, Laguna de Perlas, La Cruz del Río Grande, Rama, Muelle de los Bueyes, Bocana de Paiwas, El Tortuguero y la Desembocadura de Río Grande. Su población pluricultural y multilingüe, es descendiente de pueblos indígenas, afro indígenas y afrodescendientes, constituyéndola principalmente Mestizos (81%), Creoles (8.5%) Miskitus (6.5%), Uwas (2%), Garífunas (1.5%) y Ramas (0.5%) (*Región Autónoma Costa Caribe Sur (RACCS) | Visita Nicaragua, s. f.*)

#### 3.2.2. Trauma craneoencefálico

El trauma craneoencefálico (TCE) se define como una alteración en la función cerebral debido a una fuerza externa, golpe o herida en la cabeza que puede ocasionar una disminución del nivel de conciencia, un periodo de Amnesia Postraumática (APT),

fractura craneal y/o alteraciones en la evaluación neurológica (Díaz & Guevara, 2016). Se ha calificado como epidemia silenciosa por combinar una gran incidencia y enormes cargas sociales con muy poca investigación (Santa Cruz Hernández, 2021).

### 3.2.3. Escala Coma de Glasgow

Escala Coma de Glasgow (ECG), es una escala de aplicación neurológica que permite medir el nivel de conciencia de una persona, se usa para determinar el estado de un paciente con TCE; la exploración neurológica de un paciente con TCE debe ser simple, objetiva y rápida (Generación Elsevier, 2017). Se toma en cuenta tres criterios de observación clínica: la respuesta ocular, verbal y motora. Cada uno de estos criterios se evalúa mediante una subescala. Cada respuesta se puntúa con un número, siendo cada una de las subescalas evaluadas independientemente. En esta escala el estado de conciencia se determina sumando los números que corresponden a las respuestas del paciente en cada subescala. El puntaje más bajo es 3, mientras que la más alta es 15, entre 15-13 se considera normal, 12-9 moderado y menor que 9 grave (Sanfeliu & Suñé, 2002).

### 3.2.4. Presión arterial

La presión arterial (PA) es la presión que ejerce la sangre en las arterias al transportarse por ellas, consiste en la medida de dos valores, la Presión Arterial Sistólica (PAS) y la Presión Arterial Diastólica (PAD) y se mide en milímetros de mercurio (mmHg) (Corahealth, s. f.). La PAS depende del volumen del latido y de la rigidez de los vasos y PAD se correlaciona directamente con la resistencia periférica (*Presión arterial*, 2004).

**Tabla 2.** Clasificación de PA

Categoría	PAS (mmhg)	PAD (mmhg)
PA ideal	< 120	< 80
PA normal alta	120-139	80-89
Hipertensión leve	140-159	90-99
Hipertensión moderada	160-179	100-109
Hipertensión severa	≥ 180	≥ 110

Fuente: (Organización Mundial de la Salud (OMS), s. f.)

### 3.2.5. Frecuencia de Ritmo cardiaco

Las Frecuencia de Ritmo Cardíaco (son sensaciones de latidos cardíacos que se perciben como si el corazón estuviera latiendo con violencia o acelerado. Pueden sentirse en el pecho, la garganta o el cuello. Normalmente, el corazón late entre 60 y 100 veces por minuto. En las personas que hacen ejercicio puede caer por debajo de 60 latidos por minuto (MedlinePlus enciclopedia médica, s. f.).

### 3.2.6. Frecuencia respiratoria

La Frecuencia Respiratoria (FR) es la cantidad de respiraciones por minuto, lo normal en adultos es de 12 a 20 respiraciones por minuto y para los niños varía según la edad (Publicaciones de medicina, 2007).

**Tabla 3.** Frecuencia respiratoria por edad

Edad	Respiración por minuto
Desde nacimiento hasta 1 año	30-60
De 1 a 3 años	24-40
De 3 a 6 años	22-34
De 6 a 12 años	18-30
De 12 a 18 años	12-16
Mas de 18 años	12-20

Fuente: (Mochizuki et al., 2017)

### 3.2.7. Inteligencia Artificial

La inteligencia Artificial (IA) es una disciplina que incluye conceptos transversales relacionados con la lógica y el aprendizaje. Se centra en diseñar herramientas informáticas que simulen procesos de inteligencia humana que incluyen el aprendizaje, el razonamiento y la autocorrección (Aguirre et al., 2021).

### 3.2.8. Aprendizaje Automático

El Aprendizaje Automático (AA) es un subcampo de la IA que se enfoca en el estudio científico de algoritmos y modelos estadísticos que utilizan los sistemas informáticos para realizar una tarea específica sin estar programados explícitamente. Estos algoritmos se utilizan para diversos fines, como la extracción de datos, el procesamiento de imágenes, el análisis predictivo, entre otros. La principal ventaja de usar AA es que, una vez que un algoritmo aprende qué hacer con los datos, puede hacer su trabajo automáticamente (Batta, 2020).

### 3.2.9. Scikit-learn

Es una biblioteca de AA de software libre para el lenguaje de programación Python. Cuenta con varios algoritmos de clasificación, regresión y agrupamiento, que incluyen máquinas de vectores de soporte, bosques aleatorios, aumento de gradiente, k-means y DBSCAN, y está diseñado para interactuar con las bibliotecas NumPy y SciPy (Pendregosa et al., 2019).

### 3.2.10. Aprendizaje Profundo

Deep Learning (DL) o Aprendizaje Profundo (AP), es un subcampo de aprendizaje automático en IA. Un modelo basado en AP puede aprender a realizar tareas de clasificación directamente a partir de imágenes, texto o sonido, entre otros. Sin necesidad de intervención humana para la selección de características (CEABAD, 2021).

### 3.2.11. Modelo predictivo

Son técnicas empleadas en el AA, enfocado a la recolección de datos históricos, Big Data y reconocimiento de patrones con el fin de hacer predicción de resultados para precisar la toma de decisiones mediante técnicas de análisis de datos (Candanedo et al., 2018).

### 3.2.12. Big Data

A diferencia de los datos tradicionales, el término Big Data se refiere a conjuntos masivos de datos que incluyen formatos heterogéneos: datos estructurados, no estructurados y semiestructurados (Oussous et al., 2018).

## IV. DISEÑO METODOLÓGICO

### 4.1. Área de localización del estudio

El estudio se realizó en la Región Autónoma Costa Caribe Sur (RACCS)

### 4.2. Tipo de estudio según el enfoque, amplitud o periodo

El proyecto fue cuantitativa, aplicado, de tipo descriptivo, las variables utilizadas para realizar la predicción de mortalidad fueron numéricas. Se generaron conocimientos con aplicación directa a los problemas de la salud pública, basándose en los hallazgos de la investigación pura, comprendiendo la descripción, registro, análisis e interpretación de pacientes con TCE de la región.

### 4.3. Población y muestra

#### 4.3.1. Población

La población de estudio fue infinita, conformada por los pacientes con TCE atendidos en emergencias en hospitales o centros de salud de la RACCS. Fue infinita porque se dificultó la contabilidad total de esta población por el volumen de los datos.

#### 4.3.2. Tipo de muestra y muestreo

La muestra fue no probabilística por conveniencia, se seleccionaron los hospitales o centros de salud donde la universidad BICU contaba con extensión territorial. Se incluyeron únicamente a los pacientes mayores de 16 años diagnosticados en emergencias entre 2020-2021.

Las unidades de salud seleccionadas fueron el Hospital Ernesto Sequeira Blanco del municipio de Bluefields, El Hospital Ethel Kandler del municipio de Corn Island y el Centro de Salud Perla María Norori del municipio de Laguna de Perlas. En el proceso de recolección de registros clínicos de pacientes diagnosticados con TCE en emergencias entre 2020-2021 se identificaron 40 casos.

#### 4.3.3. Técnica e instrumento de la investigación.

**Tabla 4.** Técnicas e instrumentos de la investigación

Técnicas	Instrumentos
<b>Desarrollo de los modelos</b>	
<b>Algoritmos de aprendizaje automático:</b> Random forest, K-nearest neighbor, regresión logística y árbol de decisión	<b>Lenguaje de programación:</b> Python <b>Librería de aprendizaje automático:</b> Scikit-learn

### **Validación de los modelos**

**Validación interna:** Se empleó el 20% de datos del conjunto CRASH-2.

**Encuesta de usabilidad**

**Validación externa:** Se compararon los modelos con 40 registros clínicos de pacientes recopilados.

**Entrevista**

## **4.4. Diseño Experimental**

### **4.4.1. Técnica de Recolección de Datos**

- Observación no participativa indirecta

No se tuvo ningún tipo de contacto con la muestra del estudio, se basó en los diagnósticos clínicos de los pacientes con TCE atendidos en emergencia.

- Recopilación documental

Se llevó a cabo una revisión exhaustiva del estado del arte, para valorar diferentes tipos de algoritmos AA aplicados en el desarrollo de modelos predictivos.

### **4.4.2. Confiabilidad y validez de los instrumentos**

La regresión logística, árbol de decisión y random forest (Matsuo et al., 2020), así como el K-Nearest Neighbor (KNN) (Hsu et al., 2021) son algoritmos que han sido empleados en diversos modelos para la predicción de mortalidad en pacientes de TCE demostrando un gran rendimiento en esta labor.

## **4.5. Operacionalización de la variable**

**Tabla 5.** Operacionalización de variables

<b>Variables</b>	<b>Instrumento de medición</b>	<b>Unidades</b>	<b>Frecuencia de monitoreo</b>
<b>Identificar los requerimientos necesarios para la construcción del modelo predictivo</b>			
Tecnologías y herramientas de desarrollo	Documentos científicos	Adimensional	Única
Medidas clínicas	Observación no participativa indirecta		
Datos demográficos	Observación no participativa indirecta		

Variables	Instrumento de medición	Unidades	Frecuencia de monitoreo
<b>Identificar los requerimientos necesarios para la construcción del modelo predictivo</b>			
<b>Diseñar el modelo predictivo que permita la estimación de riesgo de mortalidad en pacientes con trauma craneoencefálico</b>			
Scikit-learn	Python	Adimensional	Ver cronograma
<b>Construir el modelo de estimación de riesgo de mortalidad en paciente con trauma craneoencefálico de la Región Autónoma Costa Caribe Sur Nicaragüense</b>			
Edad	Historia clínica	> 16 años	2
Sexo		M/F	
Etnia		Grupo étnico	
ECG		3-15 puntos	
PA		PAS/PAD	
FR		12-20 minuto	
FRC		60-100 minuto	
Saturación de oxígeno		%	
<b>Validar el modelo construido, mediante técnicas de correlación</b>			
Sensibilidad	Algoritmos AA	Adimensional	Ver cronograma
Especificidad			
Predicción			
Precisión			
Área bajo la curva (AUC)			

#### **4.6. Análisis de datos**

Todos los análisis se realizaron con Python y Scikit-learn. se identificó la columna objetivo, entre las 44 columnas disponibles. Esta columna objetivo fue la columna con los datos necesarios para hacer las predicciones, en este caso la columna denominada “ddeath”, la que permitió hacer la distinción entre los pacientes vivos y los pacientes fallecidos. Para ello, se utilizó la librería panda en el lenguaje de programación Python

que, a través de la función csv, se logró la lectura de todo el contenido del diccionario de datos CRASH-2.

En este punto, se llevó a cabo el formateo de las fechas, lo cual permitió facilitar la manipulación de los datos. Se ajustaron los datos de la variable objetivo de manera que, con el número 1, se mostrará si el paciente está vivo y 0, si el paciente está muerto. En el caso de las celdas vacías, se llenaron con 0, a la vez que se eliminaron las columnas que se consideraron defectuosas para la predicción del modelo, de manera que se pudiera reducir el conjunto de datos. Por último, se eliminaron los valores nulos y los valores duplicados.

De igual forma, en la selección de características de la muestra, se utilizó algoritmos de selección de características, para medir la relevancia de cada característica en el modelo. Para este particular, se utilizó la prueba chi-cuadrado con la librería sklearn, trabajando con las características que se presentan a continuación.

isex: Sexo del paciente

iage: Edad del paciente

isbp: Presión arterial sistólica en mmHg (Rango 4 a 250)

icc: Tiempo de llenado capilar central en segundos

irr: Frecuencia respiratoria por minuto

ihr: Frecuencia cardíaca por minuto

bheadinj: Lesión en la cabeza (1=Yes, 0=No)

igcs: Total de puntos de la Escala de Coma Glasgow

Una vez que se logró la limpieza de los datos, estos se guardaron en un dataframe. Seguidamente, se separaron las características (X) de la variable objetivo (y), donde (X) son todas las columnas que se tomarán en cuenta y la (y) el objetivo del proyecto, en este caso, la característica ddeath. De este modo, con la función SelectKBest() se eligieron las 8 características más relevantes, mediante la utilización de la prueba ANOVA (f\_classif). La prueba ANOVA evalúa la relación entre cada característica y la variable objetivo mediante el análisis de la varianza. La variable k indica el número de características a seleccionar, en este caso, 8 características.

#### 4.7. Metodología de desarrollo

El proyecto fue llevado a cabo en la RAACS, enfocándose en 3 unidades de salud de la región, el Hospital Ethel Kandler del municipio Corn Island, el Hospital Regional Ernesto Sequeira Blanco del municipio de Bluefields y el Centro de Salud Perla María Norori del municipio de Laguna de Perlas. Se empleó la metodología de desarrollo SCRUM, lo que permitió una retroalimentación continua del modelo propuesto. Se incluyeron todos los pacientes mayores de 16 años con TCE atendidos en urgencias entre 2020-2021 y se excluyeron los pacientes que no cumplían estos criterios.

##### a) Entrenamiento y validación interna

La variable de salida del modelo fue la mortalidad en pacientes con TCE. Se entrenaron cuatro algoritmos de aprendizaje supervisado para la predicción de la mortalidad, la regresión logística, árbol de decisión, Random Forest y el K-NN; Que, a diferencia del aprendizaje no supervisado, en el aprendizaje supervisado los datos de entrenamiento están etiquetados y el algoritmo de aprendizaje se entrena para poder predecir etiquetas de datos nuevos.

El Random Forest, es un algoritmo ampliamente utilizado que combina el resultado de múltiples árboles de decisión para lograr un único resultado. Su facilidad de uso y flexibilidad han impulsado su adopción, ya que maneja problemas tanto de clasificación como de regresión. (IBM, s. f.)

K-NN es uno de los algoritmos de clasificación más simples, incluso con tal simplicidad puede dar resultados altamente competitivos, es un clasificador de aprendizaje, que utiliza la proximidad para realizar clasificaciones o predicciones sobre la agrupación de un conjunto de datos individual. (Diaz, s. f.)

Para entrenar y validar internamente los modelos, se utilizó la validación cruzada, proceso que cada modelo repitió con diferentes muestras de conjuntos de entrenamiento y prueba para la repetibilidad de los resultados; esta es una técnica para evaluar modelos de ML en el cual se entrenan más de un algoritmo de aprendizaje. Las métricas utilizadas para definir el modelo de mejor rendimiento fueron la precisión, la sensibilidad, la especificidad y la curva ROC.

**Tabla 6.** Métricas utilizadas para definir el modelo con el mejor rendimiento

Métricas	Significado
Precisión	Indica la capacidad del modelo para predecir verdaderos positivos y verdaderos negativos.
Sensibilidad	Indica la capacidad del modelo para detectar verdaderos positivos, es decir, la capacidad del modelo para identificar correctamente los casos positivos.
Especificidad	Indica la capacidad del modelo para detectar verdaderos negativos, es decir, la capacidad del modelo para identificar correctamente los casos negativos.
Curva ROC	Muestra la relación entre la tasa de verdaderos positivos (Sensibilidad) y la tasa de falsos positivos (Especificidad) a medida que se ajusta el umbral de decisión del modelo.

### b) Usabilidad del modelo

La validación de usabilidad del modelo se realizó en dos momentos, primero se presentó el modelo resultante a las autoridades de los municipios de Corn Island (Alcalde del municipio, Director del Hospital Ethel Kandler, Secretario Político del municipio, Director de BICU- Corn Island y Director del departamento de investigación y posgrado de la universidad BICU) y Laguna de Perla (Directora del Centro de Salud Perla María Norori, Secretaria política del municipio y Directora de BICU – Laguna de Perlas), con el fin de recibir retroalimentación y garantizar mediante convenios el acceso al registro clínico del hospital y centro de salud para realizar la validación externa del modelo final. Posteriormente, el modelo fue presentado al personal clínico del hospital y centro de salud (enfermeras, médicos generales y médicos especialistas), con el fin de asegurar la interacción con el modelo para evaluar su usabilidad y recolectar retroalimentación para asegurar un modelo adecuado a su contexto.

## V. RESULTADOS Y DISCUSIÓN

### 5.1. Diseño y construcción de los modelos

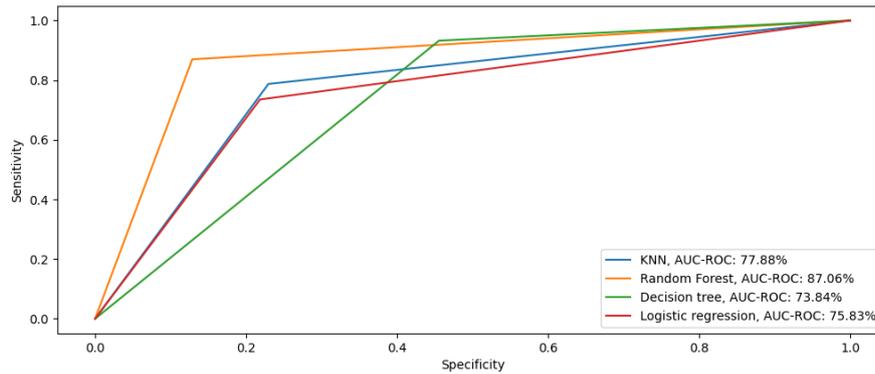
Se identificaron cuatro algoritmos de aprendizaje automático con buen rendimiento en la discriminación de mortalidad en pacientes con TCE, siendo estos la regresión logística, el árbol de decisión, Random Forest y K-Nearest Neighbor. Al tratarse de algoritmos supervisados, fue necesario contar con un conjunto de datos masivo con datos etiquetados para el proceso de entrenamiento y validación de los modelos; para este proceso se hizo uso del conjunto CRASH-2 el cual cuenta con más de 20,000 registro de pacientes con TCE.

En el diseño de los modelos, las variables edad, sexo, etnia, puntaje de la Escala de Coma de Glasgow (ECG), Presión Arterial Sistólica (PAS), Presión Arterial Diastólica (PAD), ritmo cardiaco (RC), frecuencia respiratoria (FR), lesión importante en la cabeza y la saturación de oxígeno fueron seleccionadas para ser incluidas en el modelo. Cabe destacar que las variables etnográficas no son determinantes en la predicción, pero fueron incluidas como posible fuente de información para estudios futuros.

El proceso de limpieza de datos y la selección de la fuente de datos jugaron un papel muy importante en el desempeño final del modelo predictivo; La selección de variables predictivas fue adecuada, aun cuando las variables etnográficas no jugaron un papel importante en la predicción, pero por su gran relevancia en el contexto multiétnico de la población de esta región, no se pudieron excluir.

### 5.2. Evaluación de los modelos

La métrica principal utilizada para evaluar el rendimiento de los diferentes modelos entrenados fue la curva ROC, que muestra la relación entre la tasa de verdaderos positivos y la tasa de falsos positivos del modelo, es una métrica comúnmente utilizada para evaluar el rendimiento de modelos basados en aprendizaje automático. Debido a la naturaleza de los datos médicos, también se incluyeron métricas de precisión, sensibilidad y especificidad para definir el rendimiento del modelo.



**Figura 2.** Métricas de la curva ROC

La curva ROC para los modelos K-NN, Random Forest, árbol de decisión y regresión logística fue 77.88%, 87.06%, 73.84% y 75.83% respectivamente (Figura 2). Una curva ROC ideal estaría cerca de la esquina noroeste de la figura, lo que significaría que el modelo tiene una alta tasa de verdaderos positivos, como se puede ver en la Figura 2, Random Forest refleja un mejor desempeño en la detección de verdaderos positivos. En cuanto al resto de métricas, Random Forest obtuvo una precisión del 87.06%, una sensibilidad del 86.72% y una especificidad del 86.99%; K-NN obtuvo una precisión de 77.87%, una sensibilidad de 76.81% y una especificidad de 78.72%; Árbol de decisión obtuvo una precisión de 86.48%, una sensibilidad de 85% y una especificidad del 87.66%; Regresión logística obtuvo una precisión de 75.03%, una sensibilidad de 76.42% y una especificidad de 72.39% (Tabla 7).

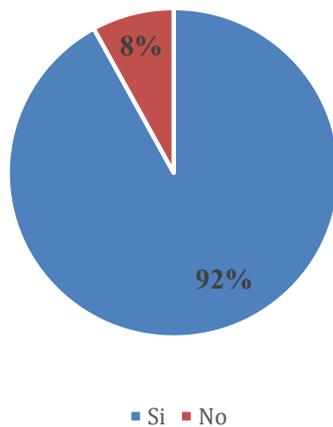
**Tabla 7.** Métricas de precisión, sensibilidad y especificidad

Métricas	Random Forest	K-NN	Árbol de decisión	Regresión logística
Precisión	87.06	77.87	86.48	75.03
Sensibilidad	86.72	76.81	85	76.42
Especificidad	86.99%	78.72	87.66	72.39

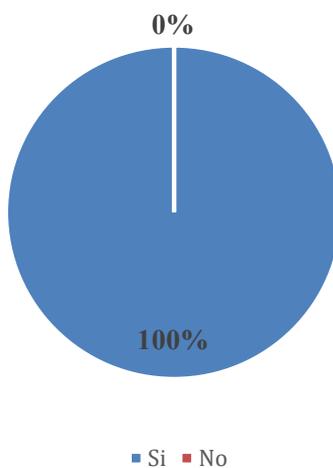
En los cuatro modelos, las variables ECG, PAS, PAD, FC, FR, lesión importante en la cabeza y saturación de oxígeno demostraron tener un impacto significativo en la predicción de la mortalidad en pacientes con TCE. En cuanto a las variables edad, sexo y etnia mostraron menor impacto en la predicción.

### 5.3. Evaluación de la usabilidad

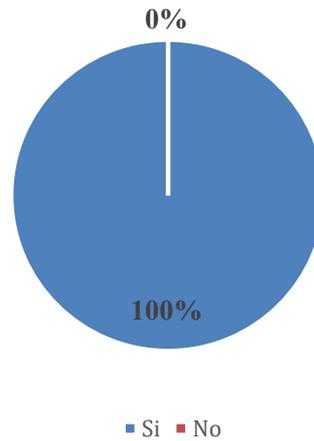
Luego de presentar el modelo resultante al personal médico y lograr su interacción con el mismo, se aplicó una encuesta para evaluar la usabilidad del modelo en el Hospital Ethel Kandler, en la que se identificó un alto índice de aceptabilidad. Los resultados se muestran en las Figuras 3-6, donde se evaluó la utilidad del modelo, su interfaz, su capacidad para mejorar la atención de los pacientes con TCE y su contribución al desarrollo tecnológico del municipio.



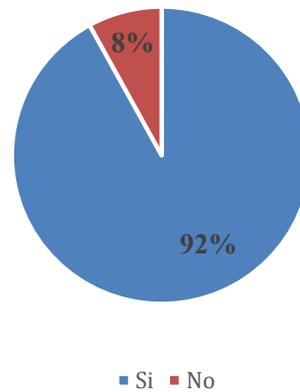
**Figura 3.** Utilidad del modelo como apoyo para la atención y seguimiento de pacientes con TCE – Hospital Ethel Kandler (Corn Island)



**Figura 4.** Interfaz amigable – Hospital Ethel Kandler (Corn Island)

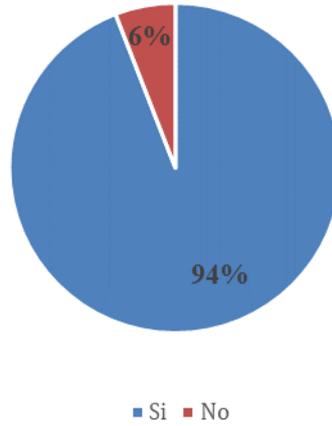


**Figura 5.** El modelo mejoraría la atención a pacientes con TCE – Hospital Ethel Kandler (Corn Island)

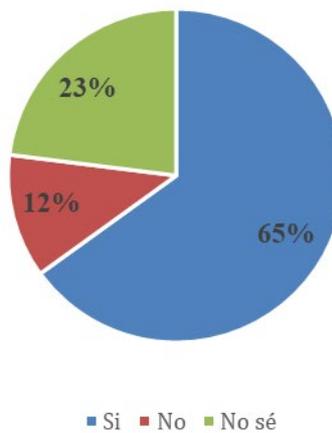


**Figura 6.** Contribuye al desarrollo tecnológico del municipio – Hospital Ethel Kandler (Corn Island)

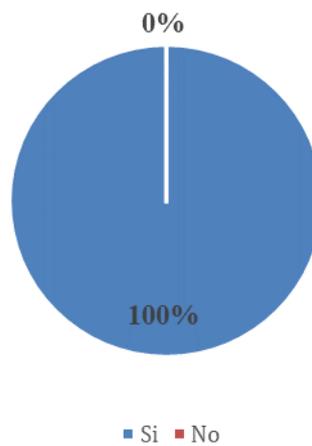
Al hacer la presentación del modelo al personal médico del centro de Salud Perla María Norori en Laguna de perlas y aplicar el mismo instrumento, se pudo notar un comportamiento similar en comparación al personal del hospital Ethel Kandler en Corn Island, con un alto grado de aceptación, los cuales se reflejan en las figuras 7-10. Siendo la única discrepancia la percepción referente a la sencillez del interfaz de usuario empleado en la demostración del modelo.



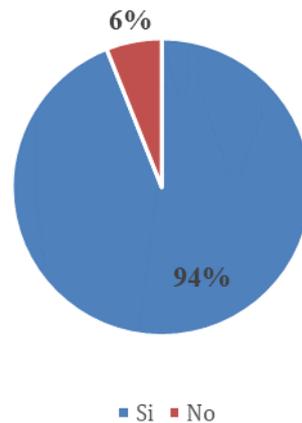
**Figura 7.** Utilidad del modelo como apoyo para la atención y seguimiento de pacientes con TCE – Centro de Salud Perla María Norori (Laguna de Perlas)



**Figura 8.** Interfaz amigable – Centro de Salud Perla María Norori (Laguna de Perlas)



**Figura 9.** El modelo mejoraría la atención a pacientes con TCE – Centro de Salud Perla María Norori (Laguna de Perlas)



**Figura 10.** Contribuye al desarrollo tecnológico del municipio – Centro de Salud Perla María Norori (Laguna de Perlas)

Se identificó una alta tasa de aceptabilidad en ambas localidades; sin embargo, la falta de personal especializado en la atención del TCE, se pudo ver reflejado en la poca retroalimentación obtenida por parte de los grupos. Es importante priorizar la presencia de expertos para asegurar un modelo relevante a la realidad de estas unidades de salud, tomando en cuentas sus atributos y limitaciones. El tiempo de iteración fue corto por lo que sería prudente una evaluación más extensa, durante el cual el personal de estas unidades de salud pueda tener una mayor interacción con el modelo en su trabajo diario, lo cual podría proporcionar más información pertinente.

Debido a limitaciones en el acceso a los datos, solo se pudieron validar los modelos predictivos en dos de las tres unidades de salud participantes. Sin embargo, las dos unidades de salud en las que se validó el modelo, representan la demografía de los pacientes y las prácticas clínicas típicas observadas en la población objetivo. No obstante, durante el proceso de desarrollo y validación interna de los modelos, en base a la metodología trabajada, se tuvieron varias sesiones de retroalimentación con personal de esta unidad médica, en donde los comentarios fueron alentadores referente a la usabilidad del modelo, lo cuál es coherente con los resultados obtenidos en las demás unidades de salud.

## VI. CONCLUSIONES

El objetivo principal de la investigación fue el desarrollo y validación de un modelo predictivo capaz de estimar el riesgo de mortalidad en pacientes con TCE basado en aprendizaje automático para la RACCS, con el fin de brindar un apoyo a los profesionales de la salud a la hora de identificar aquellos pacientes de gravedad y así poder tomar decisiones de tratamiento informadas.

Se llevó a cabo una combinación entre análisis de datos y comentarios del personal de salud para evaluar el rendimiento y usabilidad del modelo predictivo. Los datos fueron recopilados de tres unidades de salud de la RACCS, El Hospital Ernesto Sequeira Blanco (Bluefields), El Hospital Ethel Kandler (Corn Island) y el Centro de Salud Perla María Norori (Laguna de Perlas).

Para el desarrollo del modelo se entrenaron y evaluaron 4 diferentes algoritmos basados en aprendizaje automático, los cuales fueron la regresión logística, el árbol de decisión, Random Forest y K-Nearest Neighbor. El algoritmo de Random Forest demostró el mejor rendimiento con un área bajo la curva ROC del 87.06%, sensibilidad del 86.72%, especificidad del 86.99% y precisión del 87.06%.

Las variables con mayor impacto en la predicción de mortalidad fueron la puntuación de la Escala de Coma de Glasgow, Presión Arterial Sistólica, Presión Arterial Diastólica, Frecuencia Cardíaca, Frecuencia Respiratoria, lesión significativa en la cabeza y la saturación del oxígeno. De igual manera se tomaron en cuenta variables etnográficas, que si bien no presentan relevancia en la predicción de mortalidad, dada la peculiaridad de la región, fueron tomadas en cuenta para servir de base en futuras investigaciones.

En la evaluación de usabilidad, el modelo fue percibido como útil, facilidad de uso y capaz de mejorar la atención a los pacientes, sin embargo, se requirieron pruebas detalladas y comentarios de personal especializado en la atención a pacientes de TCE.

## VII. RECOMENDACIONES

1. Validar aún más el modelo predictivo en otras unidades de salud de la región para garantizar la generalización en toda la región.
2. Colaborar activamente con personal de salud especializada en la atención a pacientes de TCE para recopilar información detallada sobre los beneficios del modelo y cómo se relaciona con su práctica clínica.
3. Implementar el modelo predictivo en un programa piloto para evaluar su impacto en la atención a pacientes con TCE en casos reales.
4. Monitorear y refinar continuamente el modelo predictivo a medida que haya nuevos datos disponibles y las prácticas clínicas de las unidades de salud de la región evolucionen.

## VIII. REFERENCIAS

- Aguirre, F., Carballo, L., González, X., & Gigirey, V. (2021). Inteligencia Artificial aplicada a imágenes médica. *Derecho y Realidad*, 47-58. <https://doi.org/10.19053/16923936.v18.n35.2020.9638>
- Álvarez Vega, M., Quirós Mora, L. M., & Cortés Badilla, M. V. (2020). *Inteligencia artificial y aprendizaje automático en medicina Artificial intelligence and machine learning in medicine*. 5(8).
- Amorim, R. L., Oliveira, L. M., Malbouisson, L. M., Nagumo, M. M., Simoes, M., Miranda, L., Bor-Seng-Shu, E., Beer-Furlan, A., De Andrade, A. F., Rubiano, A. M., Teixeira, M. J., Kolias, A. G., & Paiva, W. S. (2020). Prediction of Early TBI Mortality Using a Machine Learning Approach in a LMIC Population. *Frontiers in Neurology*, 10(January), 1-9. <https://doi.org/10.3389/fneur.2019.01366>
- Batta, M. (2020). Machine Learning Algorithms - A Review . *International Journal of Science and Research (IJ*, 9(1), 381-undefined. <https://doi.org/10.21275/ART20203995>
- Borja Santillán, M. A., Plúas Cobo, K. J., Vintimilla Herrera, B. P., & Rodríguez Orellana, G. G. (2021). Traumatismo craneoencefálico y complicaciones en accidentes motociclisticos con y sin casco Hospital León Becerra Milagro 2018-2020. *Recimundo*, 5(1), 17-30. [https://doi.org/10.26820/recimundo/5.\(esp.1\).nov.2021.17-30](https://doi.org/10.26820/recimundo/5.(esp.1).nov.2021.17-30)
- Bravo Neira, A. G., Herrera Macera, S. P., Álvarez Ordoñez, W. J., & Delgado Conforme, W. A. (2019). Traumatismo Craneoencefálico: Importancia de su Prevención y Tratamiento. *Recimundo*, 3(2), 467-483. [https://doi.org/10.26820/recimundo/3.\(2\).abril.2019.467-483](https://doi.org/10.26820/recimundo/3.(2).abril.2019.467-483)
- Candanedo, I. S., Nieves, E. H., González, S. R., Martín, M. T. S., & Briones, A. G. (2018). Machine learning predictive model for industry 4.0. *Communications in Computer and Information Science*, 877(July), 501-510. [https://doi.org/10.1007/978-3-319-95204-8\\_42](https://doi.org/10.1007/978-3-319-95204-8_42)
- CEABAD. (2021). *Inteligencia Artificial: La revolución que apenas comienza*.
- Corahealth. (s. f.). *Tensión arterial normal - valores, cambios y medición*. Recuperado 16 de mayo de 2022, de <https://www.cora.health/es/guia/tension-arterial-normal/>

- Díaz, M., & Guevara, P. (2016). Desarrollo de las funciones ejecutivas durante la primera infancia y su afectación ante un traumatismo craneoencefálico. *Revista Chilena de Neuropsicología*, 11(2), 40-44. <https://doi.org/10.5839/rcnp.2016.11.02.07>
- Díaz, R. (s. f.). *Algoritmo KNN*. Recuperado 31 de octubre de 2023, de <https://www.themachinelearners.com/algoritmo-knn/>
- Generación Elsevier. (2017). *Escala de Coma de Glasgow*. <https://www.elsevier.com/es/connect/medicina/escala-de-coma-de-glasgow>
- Giner, J., Mesa Galán, L., Yus Teruel, S., Guallar Espallargas, M. C., Pérez Lóez, C., Isla Guerrero, A., & Roda Frade, J. (2002). Article in Press Article in Press. *Effect of grain boundaries on paraconductivity of YBCO*, 1(1), 1-11.
- Herrera Martínez, M. P., Ariza Hernández, A. G., Rodríguez Cantillo, J. J., & Pacheco Hernández, A. (2018). Epidemiología del trauma craneoencefálico. *Revista Cubana de Medicina Intensiva y Emergencias*, 17(2), 3-6.
- Hsu, S. Der, Chao, E., Chen, S. J., Hueng, D. Y., Lan, H. Y., & Chiang, H. H. (2021). Machine learning algorithms to predict in-hospital mortality in patients with traumatic brain injury. *Journal of Personalized Medicine*, 11(11). <https://doi.org/10.3390/jpm11111144>
- IBM. (s. f.). *Random Forest*. Recuperado 25 de octubre de 2023, de <https://www.ibm.com/topics/random-forest>
- Martin, G. P., Sperrin, M., Snell, K. I. E., Buchan, I., & Riley, R. D. (2021). Clinical prediction models to predict the risk of multiple binary outcomes: a comparison of approaches. *Statistics in Medicine*, 40(2), 498-517. <https://doi.org/10.1002/sim.8787>
- Matsuo, K., Aihara, H., Nakai, T., Morishita, A., Tohma, Y., & Kohmura, E. (2020). Machine Learning to Predict In-Hospital Morbidity and Mortality after Traumatic Brain Injury. *Journal of Neurotrauma*, 37(1), 202-210. <https://doi.org/10.1089/neu.2018.6276>
- MedlinePlus enciclopedia médica. (s. f.). *Palpitaciones cardíacas*. Recuperado 17 de mayo de 2022, de <https://medlineplus.gov/spanish/ency/article/003081.htm>
- Mochizuki, K., Shintani, R., Mori, K., Sato, T., Sakaguchi, O., Takeshige, K., Nitta, K., & Imamura, H. (2017). Importance of respiratory rate for the prediction of clinical deterioration after emergency department discharge: a single-center, case-control study. *Acute Medicine & Surgery*, 4(2), 172-178. <https://doi.org/10.1002/AMS2.252>

- Montero Rodríguez, J. C. de J., Roshan Biswal, R., & la Cruz, E. S. de. (2019). Algoritmos de aprendizaje automático de vanguardia para el diagnóstico de enfermedades. *Research in Computing Science*, 148(7), 455-468. <https://doi.org/10.13053/racs-148-7-34>
- Montero, T. (2012). Traumatismos. *Revista Cubana de Medicina Militar*, 41(1), 1-3.
- Morales Acevedo, M. J., & Mora García, E. (1986). *Analysis of Incipient Deformation of Brittle Work Material Under Orthogonal Cutting Conditions*. 277-280.
- Obermeyer, Z., & Lee, T. H. (2017). Lost in Thought — The Limits of the Human Mind and the Future of Medicine. *The NEW ENGLAND JOURNAL of MEDICINE* Lost, 1209-1211.
- OPS/OMS. (s. f.). *Discapacidades y traumatismos causados por el tránsito*. Recuperado 16 de marzo de 2022, de [https://www3.paho.org/mex/index.php?option=com\\_content&view=article&id=490:marco-conceptual&Itemid=380](https://www3.paho.org/mex/index.php?option=com_content&view=article&id=490:marco-conceptual&Itemid=380)
- Organización Mundial de la Salud (OMS). (s. f.). *Clasificación de presión arterial*. Recuperado 17 de mayo de 2022, de <https://www.who.int/es/>
- Organización Mundial de la Salud (OMS). (2018). *TCE - Traumatismo craneoencefálico - RELACISIS*. <https://www3.paho.org/relacsis/index.php/en/foros-relacsis/foro-becker-fci-oms/61-foros/consultas-becker/938-tce-traumatismo-craneoencefalico>
- Oussous, A., Benjelloun, F. Z., Ait Lahcen, A., & Belfkih, S. (2018). Big Data technologies: A survey. *Journal of King Saud University - Computer and Information Sciences*, 30(4), 431-448. <https://doi.org/10.1016/j.jksuci.2017.06.001>
- Pendregosa, F., Varoquaux, G., Gramfort, A., Michel, V., & Thirion, B. (2019). Scikit-learn: Machine Learning in Python. *Environmental Health Perspectives*, 127(9), 097008. <https://doi.org/10.1289/EHP4713>
- Presión arterial*. (2004). 23, 155-156.
- Publicaciones de medicina. (2007). *Respiración*. Publicaciones de medicina. <http://publicacionesmedicina.uc.cl/ManualSemiologia/190Respiracion.htm>
- Raj, R., Luostarinen, T., Pursiainen, E., Posti, J. P., Takala, R. S. K., Bendel, S., Konttila, T., & Korja, M. (2019). Machine learning-based dynamic mortality prediction after traumatic brain injury. *Scientific Reports*, 9(1), 17672. <https://doi.org/10.1038/s41598-019-53889-6>



- Rajula, H. S. R., Verlato, G., Manchia, M., Antonucci, N., & Fanos, V. (2020). Comparison of conventional statistical methods with machine learning in medicine: Diagnosis, drug development, and treatment. *Medicina (Lithuania)*, 56(9), 1-10. <https://doi.org/10.3390/medicina56090455>
- Región Autónoma Costa Caribe Sur (RACCS) | Visita Nicaragua.* (s. f.). Recuperado 5 de mayo de 2022, de <https://www.visitanicaragua.com/raccs/>
- Riley, R. D., Ensor, J., Snell, K. I. E., Harrell, F. E., Martin, G. P., Reitsma, J. B., Moons, K. G. M., Collins, G., & van Smeden, M. (2020). Calculating the sample size required for developing a clinical prediction model. *BMJ*, 368, m441. <https://doi.org/10.1136/bmj.m441>
- Sanfeliu, V., & Suñé, B. (2002). Escala de Glasgow. *Revista de enfermería (Barcelona, Spain)*, 25(3), 57-58.
- Santa Cruz Hernández, L. M. S. (2021). *Traumatismo craneoencefálico en edades pediátricas.*



## IX. ANEXOS

### 9.1. Cronograma de actividades

Actividades	2023												2024											
	Septiembre				Octubre				Noviembre				Diciembre				Enero				Febrero			
	S1	S2	S3	S4	S1	S2	S3	S4	S1	S2	S3	S4	S1	S2	S3	S4	S1	S2	S3	S4	S1	S2	S3	S4
Identificar los requerimientos del modelo.	X	X																						
Diseño del modelo.		X	X																					
Construcción del modelo.				X	X																			
Validación interna del modelo.					X																			
Validación externa del modelo.						X	X	X	X													X	X	
Retroalimentación del modelo.				X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X	X

## 9.2. Recursos: humanos, materiales y financieros

N.º	Concepto	Unidad	Cantidad	Costo Unitario	Costo Total
<b>PRIMERA FASE</b>					
<b>Equipos e Insumos de Campo</b>					
1	Viático – validación del modelo predictivo en Hospital Ethel Kandler (Corn Island)	Persona	4	C\$ 11,737.00	C\$ 46,948.00
2	Viático – validación del modelo predictivo en Centro de Salud Perla María Norori (Laguna de Perlas)	Persona	4	C\$ 6,220.00	C\$ 24,880.00
3					
4					
5					
6					
7					
8					
9					
10					
11	<b>Sub-Total</b>				<b>C\$ 71,828.00</b>
<b>SEGUNDA FASE</b>					
<b>Informe Final</b>					
12					
13					
14					
15					
16	<b>Sub-Total</b>				<b>C\$ 0.00</b>
<b>INVERSIÓN FINAL</b>					
17	<b>Total</b>				<b>C\$ 71,828.00</b>