

UNIVERSIDAD TÉCNICA DEL NORTE



Facultad de Ingeniería en Ciencias Aplicadas

Carrera de Software

**DESARROLLO DE UNA APLICACIÓN WEB PARA LA DETECCIÓN
TEMPRANA DE ESTRÉS EN ESTUDIANTES DE LA UTN UTILIZANDO
TÉCNICAS DE APRENDIZAJE AUTOMÁTICO.**

Trabajo de grado previo a la obtención del título de Ingeniera de Software
presentado ante la ilustre Universidad Técnica del Norte.

Autor:

Lenin Isaac Romero Romo

Director:

PhD. García Santillán Iván Danilo

Ibarra – Ecuador

2024



UNIVERSIDAD TÉCNICA DEL NORTE

BIBLIOTECA UNIVERSITARIA

AUTORIZACIÓN DE USO Y PUBLICACIÓN A FAVOR DE LA UNIVERSIDAD TÉCNICA DEL NORTE

1. IDENTIFICACIÓN DE LA OBRA

En cumplimiento del Art. 144 de la Ley de Educación Superior, hago la entrega del presente trabajo a la Universidad Técnica del Norte para que sea publicado en el Repositorio Digital Institucional, para lo cual pongo a disposición la siguiente información:

DATOS DE CONTACTO			
CÉDULA DE IDENTIDAD:	0402185961		
APELLIDOS Y NOMBRES:	Lenin Isaac Romero Romo		
DIRECCIÓN:	Hugo Guzmán Lara y pasaje 7		
EMAIL:	liromeror@utn.edu.ec		
TELÉFONO FIJO:		TELÉFONO MÓVIL:	0978897422

DATOS DE LA OBRA	
TÍTULO:	Desarrollo de una aplicación web para la detección temprana de estrés en estudiantes de la UTN utilizando técnicas de aprendizaje automático.
AUTOR (ES):	Lenin Isaac Romero Romo
FECHA DE APROBACIÓN: DD/MM/AAAA	8/10/2024
PROGRAMA:	<input checked="" type="checkbox"/> PREGRADO <input type="checkbox"/> POSGRADO
TÍTULO POR EL QUE OPTA:	Ingeniero en software
DIRECTOR:	PhD. García Santillán Iván Danilo
ASESOR	Ing. Luz Maria Tobar Subia Contenido MSc.

2. CONSTANCIAS

El autor (es) manifiesta (n) que la obra objeto de la presente autorización es original y se la desarrolló, sin violar derechos de autor de terceros, por lo tanto, la obra es original y que es (son) el (los) titular (es) de los derechos patrimoniales, por lo que asume (n) la responsabilidad sobre el contenido de la misma y saldrá (n) en defensa de la Universidad en caso de reclamación por parte de terceros.

Ibarra, a los 8 días del mes de octubre de 2024

EL AUTOR:

Lenin Isaac Romero Romo
0402185961

CERIFICACIÓN DIRECTOR

Ibarra, 8 de octubre del 2024

CERTIFICACIÓN DIRECTOR DEL TRABAJO DE TITULACIÓN

Por medio del presente yo PhD. Iván García, certifico que el sr. Lenin Isaac Romero Romo portador de la cedula de ciudadanía numero 0402185961, ha trabajado en el desarrollo del proyecto de grado "Desarrollo de una aplicación web para la detección temprana de estrés en estudiantes de la UTN utilizando técnicas de aprendizaje automático.", previo a la obtención del Título de Ingeniero en software realizado con interés profesional y responsabilidad que certifico con honor de verdad

Es todo en cuanto puedo certificar a la verdad

Atentamente



PhD. Iván Danilo García Santillán
DIRECTOR DE TRABAJO DE GRADO

DEDICATORIA

Con el corazón lleno de gratitud y emoción, dedico esta tesis:

A mi madre, por ser un pilar fundamental en mi vida, la que me ha ayudado en todo momento, la persona que tiene un corazón muy bueno, lleno de empatía. Por todas las llamadas y todo el esfuerzo que has derramado en mí, te agradezco profundamente.

A mi padre, por llevar sobre sus hombros a toda una familia, por derramar sudor y esfuerzo en criarnos y darnos lo que tenemos. Solo me queda decirte gracias por ser la parte fuerte, pero llena de corazón en la familia. Gracias por todo tu esfuerzo silencioso.

A mi hermano, por estar en constante contacto conmigo, porque a pesar de la distancia, siempre nos une la sangre, y por siempre sentirte orgulloso de mí.

A mí mismo, por demostrarme que, poco a poco, se puede construir una carrera y una vida, y que pase lo que pase, siempre las cosas resultarán bien.

AGRADECIMIENTOS

Al concluir esta etapa trascendental de mi vida académica, expreso mi más profunda gratitud:

A mi familia, que siempre estuvo conmigo: a mi padre, madre y hermano, que siempre pusieron sus mejores deseos desde que inicié la carrera hasta ahora que la estoy terminando.

A mis amigos de la carrera: Gustavo, Jairo, Dylan, Heinz, Edwin C., y Jhoan, gracias por sus consejos, esas noches de diálogo general, por ser quienes son, por todos los trabajos realizados, esas madrugadas, las lágrimas, y por todo lo que compartimos. Solo me queda decirles gracias.

A mis amigos Jhon y Franchesca, por ser mi segunda familia, por ser parte de mi vida en esas noches difíciles y en esos días en los que todo se ponía turbio. Gracias por mostrarme que son personas magníficas en quienes confiar, por ayudarme en todo proceso académico y personal. Solo me queda decirles gracias.

TABLA DE CONTENIDOS

DEDICATORIA	i
ÍNDICE DE FIGURAS	x
ÍNDICE DE TABLAS	xiii
RESUMEN	xiv
ABSTRAC.....	xv
INTRODUCCIÓN.....	1
Tema	1
Problema.....	1
Antecedentes:.....	1
Situación Actual.....	1
Planteamiento del Problema	1
Objetivos.....	3
Objetivo General.....	3
Objetivos Específicos	3
Alcance	4
Metodología.....	5
Justificación	7
Justificación Tecnológica.....	8
Justificación de salud.....	8
Capítulo I.....	10
Marco Teórico.....	10
1.1 Identificación de Estrés	10
1.1.1 Estrés	10
1.1.2 Mediciones del estrés.....	10
1.1.3 Escala de Estrés Percibido (EEP)	10
1.1.4 Escala DASS-21 (Depression Anxiety and Stress Scale - 21).....	10
1.1.5 Escala GAD-7 (Generalized Anxiety Disorder 7-item Scale).....	11

1.1.6	Escala de Reajuste Psicosocial de Thomas Holmes y Richard Rahe ..	12
1.1.7	Estrés en estudiantes universitarios	14
1.1.8	Estrés académico	14
1.2	Hardware de reconocimiento de biométricos del estrés	15
1.2.1	Sensores biométricos de medición del estrés	15
1.2.2	Señales biométricas de medición del estrés.....	19
1.3	Tecnologías de inteligencia artificial con interfaz web	20
1.3.1	Lenguaje de programación de la aplicación fronted web detección de estrés	20
1.3.2	librerías de desarrollo fronted para páginas web	21
1.3.3	Lenguaje de programación para entrenar el modelo de Inteligencia Artificial y el desarrollo del backend de la aplicación web.....	21
1.3.4	Framework de desarrollo backend para la aplicación web.....	21
1.3.5	Base de datos para el guardado de los datos de los biométricos	21
1.4	Modelo de Inteligencia artificial para la clasificación de estrés en estudiantes	22
1.4.1	Normalización de los datos	22
1.4.2	Segmentación temporal de los datos	22
1.4.3	Las Redes Neuronales Artificiales.....	22
1.5	Machine learning	23
1.5.1	Arquitectura de red neuronal profunda (RNA).....	23
1.5.2	La capa de salida de una neurona con una función de activación línea 24	
1.5.3	Función de pérdida error cuadrático medio (MSE).....	25
1.5.4	Entrenar el modelo utilizando un conjunto diverso y representativo de datos de diferentes lugares para mejorar la generalización.	25
1.6	Arquitectura SVM (Super vector machine).....	26
1.7	Arquitectura Random forest	26

1.8	Arquitectura XGBoost.....	27
1.9	Metodologías utilizadas para el desarrollo web como para el desarrollo del modelo de inteligencia artificial.	28
1.9.1	Metodología SCRUM.....	28
1.9.2	Metodología CRISP-DM.....	29
1.10	Trabajos relacionados	30
1.10.1	Stress-Lysis: A DNN-Integrated Edge Device for stress Level Detection in the IoMT	30
1.10.2	Introducing WESAD, a Multimodal Dataset for Wearable stress and Affect Detection	31
1.10.3	Thermal Comfort and Stress Recognition in Office Environment	32
1.10.4	SaYoPillow: Blockchain-Integrated Privacy-Assured IoMT Framework for Stress Management Considering Sleeping Habits.....	32
1.10.5	Depression Anxiety Stress Scales Responses.....	33
1.11	Selección de dispositivos.....	33
CAPÍTULO 2		35
2.1	Visión general del proyecto	35
2.1.1	Planificación	35
2.1.2	Entregables del proyecto	36
2.2	Recopilación y análisis de datos.....	37
2.3	Creación y entrenamiento del modelo de inteligencia artificial para la detección del estrés.....	42
2.3.1	Variables del modelo de inteligencia artificial	43
2.3.1.1	Frecuencia Cardíaca con Pulse Sensor	43
2.3.1.2	Temperatura Corporal con el Sensor Gikfun DS18B20	44
2.3.1.3	Frecuencia Respiratoria con el Sensor MQ-3 Modificado	44
2.3.1.4	Rangos Normales de Medidas Fisiológicas en Personas Adultas Jóvenes	44
2.3.2	Escala de medición del estrés	45

2.3.2.1	Encuesta de estrés percibido.....	45
2.3.2.1.1	<i>Rango de Clasificación para la Escala de Estrés Percibido (PSS-14)</i>	45
2.3.2.1.2	<i>Cómo interpretar las puntuaciones:</i>	45
2.3.2.2	Medición de factores de estrés con biométricos.....	46
2.3.2.2.1	<i>Métodos</i>	46
2.3.2.2.2	<i>Rangos de Frecuencia Cardíaca</i>	46
2.3.2.2.3	<i>Rangos de Frecuencia Respiratoria</i>	46
2.3.2.2.4	<i>Rangos de Temperatura Corporal</i>	46
2.3.2.2.5	<i>Interpretación Combinada de los Factores Biométricos</i>	47
2.3.2.2.6	<i>Ejemplo de Cálculo</i>	47
2.3.3	Selección y preparación de modelos	47
2.3.4	Normalización de los datos	47
2.3.4.1	Fórmula de Normalización	48
2.3.4.2	Realización de la Normalización.....	48
2.3.4.3	Estrés Predicho por IA:	48
2.3.4.4	Estrés Percibido:	48
2.3.4.5	Explicación de la Normalización.....	48
2.3.5	Selección del modelo para su uso en la web	48
2.4	Creación de hardware para la recopilación de datos	49
2.4.1	Diseño en Fusion 360	50
2.4.1.1	Tapa Frontal	50
2.4.1.2	Tapa superior	51
2.4.1.3	Tapa Izquierda	52
2.4.1.4	Tapa inferior y Tapa Derecha	52
2.4.1.5	Tapa Derecha y Tapa Trasera.....	53
2.4.2	Creación de circuito interno.	54
2.4.2.1	Entradas de los Sensores	54
2.4.2.2	Iluminación y visualización de datos	55
2.4.2.3	Batería.....	56
2.4.2.4	Botonera	57
2.4.2.5	Inversor de Batería.....	57

2.4.2.6	Microcontrolador ESP32	58
2.4.2.7	Diseño de placa.....	58
2.4.2.8	Diseños en 3D de los Componentes	59
2.4.3	Codificación del dispositivo en Arduino IDE.	61
2.4.3.1	Bibliotecas y Configuración Inicial.....	61
2.4.3.2	Configuración en la Función setup()	61
2.4.3.3	Bucle Principal (loop()).....	61
2.4.3.4	Gestión del Menú	62
2.4.3.5	Funciones de Inicio de Medición.....	62
2.4.3.6	Flujograma de funcionamiento del programa.....	63
2.4.3.6.1	<i>Frecuencia Respiratoria</i>	63
2.4.3.6.2	<i>Temperatura</i>	63
2.4.3.6.3	<i>Pulso</i>	63
2.5	Creación de plataforma de recolección de datos	64
2.5.1	Desarrollo de Backend de la plataforma IA django.....	65
2.5.1.1	Rutas de encuestas estrés percibido:.....	65
2.5.1.2	Rutas de sensores biométricos:.....	66
2.5.1.3	Rutas de Usuarios:	67
2.5.1.4	Modelo Entrenado:	68
2.5.2	Elaboración de frontend de la página detección de estrés.	69
2.5.2.1	Módulos del Sitio Web	70
2.5.2.1.1	<i>Inicio</i>	70
2.5.2.1.2	<i>Estudiante</i>	71
2.5.2.1.3	<i>Pantalla de la Encuesta EEP (Escala de Estrés Percibido)</i>	72
2.5.2.1.4	<i>Signos Vitales</i>	73
2.5.2.1.5	<i>Estrés</i>	73
2.5.2.1.6	<i>Resultados Globales</i>	74
2.5.2.1.7	<i>Manual de Usuario</i>	75
2.5.2.1.8	<i>Reportar un Error</i>	75
2.5.2.1.9	<i>Autor</i>	76
CAPITULO 3	77
Validación de resultados	77

3.1	Métricas Generales de los modelos	77
3.1.1.1	Resultados del Modelo SVM.....	77
3.1.1.2	Las métricas obtenidas son las siguientes:	77
3.1.1.3	Valores Reales vs Predicciones SVM:.....	78
3.1.1.4	Histograma del Error de Predicción SVM:.....	79
3.1.1.5	Resultados del Modelo XGBoost	80
3.1.1.6	Valores Reales vs Predicciones XGBoost	81
3.1.1.7	Histograma del Error de Predicción XGBoost	82
3.1.1.8	Resultados del modelo Random Forest	83
3.1.1.9	Valores reales vs predicciones Random Forest.....	84
3.1.1.10	Histograma del Error de Predicción Random Forest.....	85
3.2	Métricas detalladas del modelo seleccionado Random Forest.....	85
3.2.1	Valores reales vs predicciones	86
3.2.1.1	Interpretación:.....	86
3.2.1.2	Fórmula Matemática:.....	86
3.2.2	Histograma de error de predicción	87
3.2.2.1	Interpretación:.....	87
3.2.2.2	Fórmula Matemática:.....	87
3.2.3	Evolución del Out-of-Bag Error vs. Número de Árboles.....	88
3.2.3.1	Interpretación:.....	88
3.2.3.2	Fórmula Matemática:.....	88
3.2.4	Evolución del CV Error vs. Número de Árboles.....	89
3.2.4.1	Interpretación:.....	89
3.2.4.2	Fórmula Matemática.....	89
3.2.5	Importancia de los Predictores	90
3.2.5.1	Interpretación:.....	90
3.2.5.2	Fórmula Matemática.....	90
3.2.6	Métricas del modelo	91
3.2.6.1	Interpretación:.....	91
3.2.6.2	Fórmulas Matemáticas:	91
3.3	Validación medica del dispositivo y modelo de estrés.	92

3.3.1.1	Eficacia en la Detección del Estrés.....	92
3.3.1.2	Validez y Confiabilidad del Dispositivo.....	92
3.3.1.3	Aspectos Éticos en la Medición del Estrés.....	93
3.3.1.4	Cumplimiento de Normativas y Estándares Médicos	93
3.3.2	Prueba de Normalidad	93
3.3.3	Prueba de Wilcoxon.....	94
3.3.3.1	Datos Utilizados:	94
3.3.3.2	Procedimiento:.....	95
3.3.3.2.1	<i>Cálculo de las diferencias:</i>	95
3.3.3.2.2	<i>Ordenamiento y asignación de rangos:</i>	96
3.3.3.2.3	<i>Suma de rangos:</i>	97
3.3.3.2.4	<i>Cálculo del estadístico de Wilcoxon :</i>	97
3.3.3.3	Resultados:	98
3.3.3.4	Interpretación:.....	98
3.3.3.5	Análisis Final.....	98
	LIMITACIONES	99
	DISCUSIONES	100
	CONCLUSIONES.....	102
	RECOMENDACIONES	103
	BIBLIOGRAFÍA:.....	104
	ANEXOS.....	109
	Anexo 1: Certificación medica del dispositivo:	109
	Anexo 2: Condigo Arduino del dispositivo	109
	Anexo 3: Modelos IA entrenados	109
	Anexo 4: Backend Plataforma WEB	109
	Anexo 5: Frontend Plataforma WEB.....	109
	Anexo 6: Prueba de estrés percibido EEP14	109

ÍNDICE DE FIGURAS

Figura 1 <i>Causas y efectos</i>	3
Figura 2 <i>Arquitectura del proyecto</i>	4
Figura 3 <i>Gráfico de la metodología CRIP-DM</i>	7
Figura 4 <i>Gráfico de la metodología SCRUM</i>	7
Figura 5 <i>Sensor EMG</i>	15
Figura 6 <i>ESP32 placa de desarrollo</i>	16
Figura 7 <i>Sensor de pulso</i>	16
Figura. 8 <i>Sensor de CO2 MQ-3</i>	17
Figura 9 <i>Sensor de temperatura</i>	17
Figura 10 <i>Pantalla LCD I2C</i>	18
Figura 11 <i>Pulsador de 4 pines</i>	18
Figura 12 <i>Señal frecuencia cardiaca</i>	19
Figura 13 <i>Señal EMG</i>	19
Figura 14 <i>Señal de temperatura corporal</i>	20
Figura 15 <i>Señal de frecuencia respiratoria</i>	20
Figura 16 <i>Representación de una RNA</i>	23
Figura 17 <i>Red Neuronal Profunda</i>	24
Figura 18 <i>Función neuronal</i>	25
Figura 19 <i>Arquitectura SVM</i>	26
Figura 20 <i>Random Forest</i>	27
Figura 21 <i>Arquitectura XGBoost</i>	28
Figura 23 <i>Metodología SCRUM</i>	29
Figura 24 <i>Metodología CRISP-DM</i>	30
Figura 25 <i>Sprint 1 Recolección de información</i>	37
Figura 26 <i>Finalización de sprint 1 datos obtenidos tablero SCRUM</i>	37
Figura 27 <i>Sprint 2 finalizado con la base de datos sin refinar</i>	40
Figura 28 <i>Finalización del sprint 3 con la base de datos lista para su uso en el modelo IA</i>	41
Figura 29 <i>Sprint 4- 5 Realizados tablero SCRUM</i>	43
Figura 40 <i>Sprint 6-7 Realizados tablero SCRUM</i>	50
Figura 41 <i>Parte frontal dispositivo de control de estrés</i>	51
Figura 42 <i>Parte superior dispositivo de control de estrés</i>	51
Figura 43 <i>Parte izquierda dispositivo de control de estrés</i>	52

Figura 44 <i>Parte inferior dispositivo de control de estrés.</i>	53
Figura 45 <i>Parte derecha dispositivo de control de estrés.</i>	53
Figura 46 <i>Parte trasera dispositivo de control de estrés.</i>	54
Figura 47 <i>Conexiones de sensores.</i>	55
Figura 48 <i>Conexiones RGB y Pantalla LSD I2C.</i>	56
Figura 49 <i>Conexiones batería interna.</i>	56
Figura 50 <i>Conexión de la botonera en configuración pull-up.</i>	57
Figura 51 <i>Circuito inversor de +5V y -5V</i>	57
Figura 52 <i>Conexiones en la ESP32</i>	58
Figura 53 <i>Placa de conexiones de los sensores con la ESP32</i>	59
Figura 54 <i>Placa 3D de componentes internos.</i>	60
Figura 55 <i>Rutas de cobre de la placa principal.</i>	60
Figura. 56 <i>Flujograma del programa del dispositivo de control de estrés</i>	64
Figura. 57 <i>Sprint 8 Realizados tablero SCRUM.</i>	65
Figura 58 <i>Ruta encuesta de estrés percibido</i>	66
Figura 59 <i>Ruta sensores biométricos.</i>	67
Figura 60 <i>Ruta de usuario</i>	68
Figura 61 <i>Integración del modelo de detección de estrés dentro de la API.</i>	69
Figura 62 <i>Sprint 9 Realizados tablero SCRUM.</i>	70
Figura 63 <i>Inicio página de control de estrés.</i>	71
Figura. 64 <i>Sprint 10 Realizados tablero SCRUM.</i>	71
Figura. 65 <i>Ingreso de estudiantes página de control de estrés.</i>	72
Figura. 66 <i>Encuesta de estrés percibido página control de estrés.</i>	72
Figura. 67 <i>Ingreso de los valores de los sensores para la página de control estrés.</i>	73
Figura. 68 <i>Niveles de estrés dentro de la plataforma control de estrés.</i>	74
Figura. 69 <i>Resultados globales control de estrés.</i>	74
Figura. 70 <i>Manual de usuario página control estres.</i>	75
Figura. 71 <i>Reportar el error de la página control de estrés.</i>	76
Figura. 72 <i>Detalles del autor de la página control de estrés.</i>	76
Figura 30 <i>Resultados del entrenamiento de SVM.</i>	78
Figura 31 <i>Valores reales vs predicciones modelo SVM.</i>	79
Figura 32 <i>Histograma del erro de predicción.</i>	80
Figura 33 <i>Resultados del entrenamiento de XGBoost.</i>	81

Figura 34	<i>Valores reales vs predicciones XGBoost</i>	82
Figura 35	<i>Histograma del error predicción.</i>	83
Figura 37	<i>Métricas del modelo Random Forest</i>	84
Figura 38	<i>Valores reales vs predicciones modelo Random Forest.</i>	84
Figura 39	<i>Histograma del error de predicción Random Forest.</i>	85
Figura 73	<i>Valores Reales vs Predicciones.</i>	86
Figura 74	<i>Histograma del error de prección</i>	87
Figura 75	<i>Evolución del out-of-bag-error vs números árboles.</i>	88
Figura 76	<i>Evolución del cv-error vs número párboles</i>	90
Figura 77	<i>Importancia de los predictores.</i>	91
Figura 78	<i>Resultados del entrenamiento.</i>	92

ÍNDICE DE TABLAS

Tabla 1 <i>Selección de sensores</i>	33
Tabla 2. <i>Planificación del proyecto para su desarrollo</i>	35
Tabla 3. <i>Entregables del proyecto de titulación</i>	36
Tabla 4 <i>Bases de datos relevantes para la creación de data set de entrenamiento</i> .	38
Tabla 5 <i>Datos de entrenamiento del modelo.</i>	41
Tabla 6 <i>Rangos normales de los sensores</i>	44
Tabla 7 <i>Explicativas de las siglas utilizadas</i>	92
Tabla 8 <i>Tabla de datos obtenidos</i>	94
Tabla 9 <i>Cálculo de las diferencias</i>	95
Tabla 10 <i>Ordenamiento y asignación de rangos</i>	96

RESUMEN

La detección temprana del estrés en estudiantes universitarios es fundamental para mejorar su bienestar y rendimiento académico. Este proyecto de titulación aborda el desarrollo de una aplicación web que emplea técnicas de aprendizaje automático para identificar niveles de estrés en estudiantes de la Universidad Técnica del Norte (UTN). El modelo de inteligencia artificial utilizado en la plataforma analiza datos biométricos, tales como la frecuencia cardíaca, la temperatura corporal y la frecuencia respiratoria, junto con la Escala de Estrés Percibido (EEP-14). La propuesta busca optimizar el proceso de detección de estrés, proporcionando un análisis objetivo y preciso que pueda ser utilizado por instituciones educativas para implementar estrategias de apoyo adecuadas.

En el Capítulo 1, se analiza la problemática del estrés en el contexto universitario, abordando sus causas y efectos. Se revisan también las aplicaciones de la inteligencia artificial en la medicina y la psicología, con un enfoque en la predicción del estrés a partir de datos biométricos. Este capítulo establece las bases teóricas necesarias para el desarrollo del modelo y la plataforma web.

El Capítulo 2 detalla el proceso de desarrollo de la aplicación web, explicando la recolección de datos, la selección del modelo de IA más adecuado y su entrenamiento. Además, se describe la implementación de la plataforma, integrando el modelo de inteligencia artificial en una interfaz web accesible y funcional, desarrollada utilizando tecnologías modernas como Django y ReactJS.

En el Capítulo 3, se presenta una evaluación exhaustiva del rendimiento del modelo, utilizando métricas de precisión y validez estadística. Se emplea la prueba t de wilcoxon para validar las predicciones del modelo frente a los datos de estrés percibido por los estudiantes. La sección concluye con un análisis crítico de los resultados obtenidos, destacando la eficacia de la aplicación en la detección temprana del estrés.

ABSTRAC

Early detection of stress in university students is crucial for improving their well-being and academic performance. This thesis presents the development of a web application that utilizes machine learning techniques to identify stress levels in students at the Universidad Técnica del Norte (UTN). The artificial intelligence model integrated into the platform analyzes biometric data, such as heart rate, body temperature, and respiratory rate, along with the Perceived Stress Scale (PSS-14). The proposed solution aims to optimize the stress detection process by providing an objective and accurate analysis that can be utilized by educational institutions to implement appropriate support strategies.

Chapter 1 analyzes the issue of stress within the university context, addressing its causes and effects. It also reviews the applications of artificial intelligence in medicine and psychology, focusing on stress prediction based on biometric data. This chapter establishes the theoretical foundations necessary for the development of the model and the web platform.

Chapter 2 details the process of developing the web application, including data collection, the selection and training of the most suitable AI model. Additionally, it describes the implementation of the platform, integrating the artificial intelligence model into an accessible and functional web interface developed using modern technologies such as Django and ReactJS.

Chapter 3 presents a comprehensive evaluation of the model's performance, using accuracy metrics and statistical validity. The Wilcoxon test is employed to validate the model's predictions against the students' perceived stress data. The section concludes with a critical analysis of the results, highlighting the effectiveness of the application in early stress detection.

INTRODUCCIÓN

Tema

Desarrollo de una aplicación web para la detección temprana de estrés en estudiantes de la UTN utilizando técnicas de aprendizaje automático

Problema

Antecedentes:

En las etapas universitarias, es común que los individuos se distancien de sus familias y se enfrenten a nuevos desafíos, como la independencia al vivir solos o la necesidad de equilibrar el trabajo y los estudios, lo que puede dificultar la interacción con las actividades académicas y desencadenar niveles significativos de estrés entre la población estudiantil. El estrés se ha convertido en una problemática cada vez más relevante en las generaciones contemporáneas, debido a la creciente competitividad en el ámbito laboral y a las limitadas oportunidades de empleo. En este contexto, aquellos que optan por cursar estudios universitarios se ven sometidos a una presión adicional que puede desencadenar niveles significativos de estrés. Este fenómeno se ve influenciado por los estilos de vida de los estudiantes, lo que hace imperativo implementar medidas preventivas para detectar y abordar el estrés antes de que afecte negativamente su rendimiento académico. Las pruebas preventivas del estrés dirigidas a la población universitaria tienen como objetivo identificar y mitigar este malestar mental antes de que impacte de manera adversa en el desempeño académico y en la salud general de los estudiantes.

Situación Actual

En la actualidad, en la Universidad Técnica del Norte, se carece de una prueba preventiva del estrés dirigida a los estudiantes, lo que resulta en la ausencia de una regulación anticipada de los niveles de estrés. Esta situación conlleva a la manifestación de problemas derivados del estrés entre la población universitaria, generando malestar y afectando negativamente el bienestar general de los estudiantes.

Planteamiento del Problema

Se puede definir el estrés como un estado de preocupación o tensión mental generado por una situación difícil (OMS, 2023). El estrés acompaña la vida de los jóvenes adultos que cruzan por la universidad, causando varias problemáticas si no se detecta y se mide su nivel con periodicidad, creando dentro de este nicho un conjunto de problemáticas tanto sociales

como de salud pública, ya que las enfermedades mentales son clasificadas como un problema que sacude nuestra sociedad actual.

En la actualidad existen un gran índice de enfermedades mentales las cuales causan malestares dentro de la población joven adulta. En los últimos años se ha incrementado las enfermedades mentales en gran parte por la sobre exigencia, la falta de estabilidad económica, falta de atención o carencia de importancia en las enfermedades mentales.

El estrés puede generar una acumulación de efectos tanto en el cerebro como en el organismo. Esta clase de estrés a largo plazo, o crónico, puede debilitar el sistema inmunológico y poner en riesgo de sufrir distintas enfermedades, desde simples resfriados hasta enfermedades más graves(cigna, 2023). Al ir creciendo esta preocupación, y con los avances de la tecnología, se fueron creando modelos con inteligencia artificial los cuales clasifican por medio de biométricos, preguntas, fotográficas, entre otros medios los niveles de estrés. Los primeros modelos de clasificación de estrés por medio de inteligencia artificial se crearon para dar de una forma más eficiente diagnósticos preventivos de estrés, esto con el fin de que se pueda tratar la enfermedad antes que esta cause más daños en las personas. Dando como origen una nueva herramienta para tratar el estrés en pacientes jóvenes, ya que no se necesita mucho tiempo para realizar las pruebas.


La inteligencia artificial (IA) está emergiendo como un componente clave en numerosas innovaciones tecnológicas.. Numerosas industrias ya lo han reconocido y han establecido la IA como parte de sus productos y flujos de trabajo (Benhamou, 2022).Los modelos de inteligencia artificial pueden clasificar grandes volúmenes de datos, al igual que pueden encontrar relaciones entre estos mismos, dando un diagnóstico preventivo que en los cuales pueden tener un nivel de precisión de 80% a 99% de precisión. Para poder realizar estos cálculos se necesita añadir un gran volumen de datos, los cuales para el caso de estrés se los recolecta por medio de biométricos, estos se colocan en las personas para tomar una muestra de su condición actual para luego compararla con miles de datos obtenidos de personas con estrés y sanas, con el fin de dar un nivel de estrés.

Los desarrolladores suelen utilizar diversas APIs (Interfaces de Programación de Aplicaciones) para incorporar funcionalidades y servicios específicos en sus aplicaciones. Cada servicio dispone de su propia API, la cual puede ser utilizada para resolver problemas relacionados con el desarrollo web, aplicaciones móviles, redes, bases de datos, entre otros. Y por supuesto los servicios para los Desarrolladores de Inteligencia Artificial cuentan con una API(AWS, 2023). Para la facilidad de las personas y para las empresas se utiliza estos modelos como un servicio, en los cuales las personas pueden utilizar estos recursos para

clasificar sus datos, en la mayoría de los casos se aplica como API, estas son consumidas por programadores o por sistemas grandes en las cuales se requiere clasificar los datos. Por lo tanto, el presente trabajo clasificara datos recolectados por medio de biométricos, encuestas, u otros artefactos de medición necesarios para entrenar un modelo de inteligencia artificial, para luego publicarlo como API.

Figura 1

Causas y efectos



Fuente: Elaboración propia.

Objetivos

Objetivo General

Desarrollo de una aplicación web de detección del estrés utilizando técnicas de aprendizaje automático para la detección temprana de estrés en estudiantes de la Universidad Técnica del Norte (UTN), con el fin de proporcionar una prueba preventiva de estrés.

Objetivos Específicos

- Analizar estudios previos que utilicen técnicas de aprendizaje automático para la detección de estrés en poblaciones similares.
- Recopilar datos relevantes sobre el nivel de estrés de los estudiantes de la UTN mediante biométricos, encuestas, u otro mecanismo de recolección de información.

- Entrenar un modelo de IA utilizando algoritmos de aprendizaje automático que permita identificar y clasificar los niveles de estrés en los estudiantes.

Alcance

Recopilación de datos: Se realizará la recopilación de datos relevantes sobre el nivel de estrés de los estudiantes de la UTN. Esto puede incluir datos respuestas a cuestionarios relacionados con el estrés, datos biométricos, entre otros.

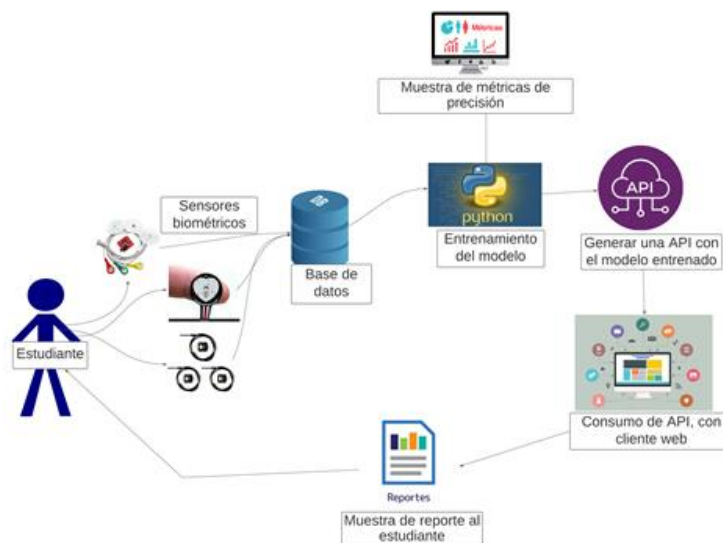
Entrenamiento del modelo de IA: Se diseñará y entrenará un modelo de IA utilizando el algoritmo de Máquinas de vectores de soporte (SVM) u otro que cumpla con las especificaciones de los datos obtenidos. El modelo se desarrollará con el objetivo de identificar y clasificar los niveles de estrés en los estudiantes.

Evaluación del modelo: Se llevará a cabo una evaluación exhaustiva del modelo de IA desarrollado. Esto implica utilizar conjuntos de datos de prueba para evaluar su desempeño y precisión en la detección temprana de estrés. Se emplearán métricas de desempeño adecuadas, como: exactitud (accuracy), precisión (precision), sensibilidad (recall o true positive rate), especificidad (specificity), valor F1 (F1 score), área bajo la curva ROC (AUC-ROC) u otras que cumplan la evaluación del modelo.

Generar una API: Una vez se entrene el modelo se implementará como una API, la cual va a hacer consumida dentro de una aplicación web, en la cual mostrara las estadísticas obtenidas por el modelo.

Figura 2

Arquitectura del proyecto



Fuente: Elaboración propia

Metodología

En el desarrollo del modelo IA se van a utilizar las siguientes metodologías, por parte del modelo del entrenamiento y verificación de los datos, se utilizará la metodología CRISP-DM, y por parte del desarrollo del api y el cliente web se utilizará SCRUM. Partiendo de estas dos metodologías, se realizará de la siguiente manera:

Metodología utilizando CRISP-DM:

En la etapa de comprensión del negocio, se llevará a cabo una revisión exhaustiva de la literatura existente sobre la detección temprana de estrés en estudiantes, así como de su impacto en el bienestar. Además, se analizarán los desafíos y necesidades específicas de la Universidad Técnica del Norte (UTN) relacionados con la detección y manejo del estrés en sus estudiantes. A partir de este análisis, se establecerán los objetivos específicos del modelo, centrándose en el desarrollo de una aplicación web que brinde una prueba preventiva de estrés.

En la fase de comprensión de los datos, se recopilarán datos relevantes sobre el nivel de estrés de los estudiantes de la UTN mediante encuestas, cuestionarios u otros medios de recolección de información adecuados. Posteriormente, se procederá a comprender la estructura y calidad de los datos recopilados, así como su pertinencia para la detección temprana de estrés en los estudiantes.

En cuanto a la preparación de los datos, se realizará una limpieza y preprocesamiento de estos, incluyendo la eliminación de valores atípicos y la gestión de los datos faltantes. Asimismo, se llevará a cabo una transformación de los datos si es necesario, como la normalización o codificación adecuada de las variables relevantes para la detección del estrés.

En la fase de modelado, se seleccionará el algoritmo de aprendizaje automático más apropiado para desarrollar el modelo de detección de estrés, como Máquinas de Vectores de Soporte (SVM) o Redes Neuronales, teniendo en cuenta la naturaleza de los datos. Además, se dividirán los datos en conjuntos de entrenamiento y prueba, y se entrenará el modelo utilizando los datos de entrenamiento.

Para la evaluación, se utilizarán métricas adecuadas como exactitud, precisión, sensibilidad, especificidad, valor F1 y área bajo la curva ROC para evaluar el rendimiento del modelo. También se emplearán técnicas de validación cruzada para garantizar la robustez del modelo y su capacidad de generalización.

Finalmente, en la etapa de despliegue, se documentará todo el proceso de desarrollo del modelo, incluyendo las etapas anteriores, los resultados obtenidos y las conclusiones.

Además, se implementará el modelo en una aplicación web, desarrollando las funcionalidades necesarias para que los estudiantes o profesionales de la UTN puedan realizar la prueba preventiva de estrés de manera eficiente y accesible.

Metodología utilizando Scrum:

En la planificación del sprint y creación del backlog, se identificarán los requisitos y funcionalidades necesarias para el desarrollo de la aplicación web. Se crearán backlog de tareas específicas que abarquen el desarrollo de la interfaz de usuario, la integración del modelo de IA y otras funcionalidades relevantes, asegurando una visión completa del proyecto.

En el primer sprint, se llevará a cabo el desarrollo de la interfaz de usuario, diseñando una experiencia intuitiva y amigable para los usuarios de la UTN. Se implementarán las funcionalidades necesarias para que los estudiantes puedan realizar la prueba preventiva de estrés y visualizar los resultados de manera clara y comprensible.


En el segundo sprint, se procederá con la integración del modelo de IA desarrollado utilizando CRISP-DM en la aplicación web. Se desarrollarán las funcionalidades necesarias para enviar los datos de los sensores y las encuestas al modelo, así como para mostrar los resultados de forma clara y comprensible.

Durante el tercer sprint, se realizarán pruebas exhaustivas de la aplicación web para verificar su funcionamiento correcto y la precisión de los resultados del modelo de IA. Se identificarán y corregirán cualquier problema o error encontrado durante las pruebas.

En el cuarto y último sprint, se documentará todo el proceso de desarrollo de la aplicación web, incluyendo los desafíos enfrentados, las decisiones tomadas y los resultados obtenidos. Finalmente, se realizará la entrega final de la aplicación web y se desplegará en un entorno de producción, asegurándose de que esté accesible para los estudiantes de la UTN.

Figura 3

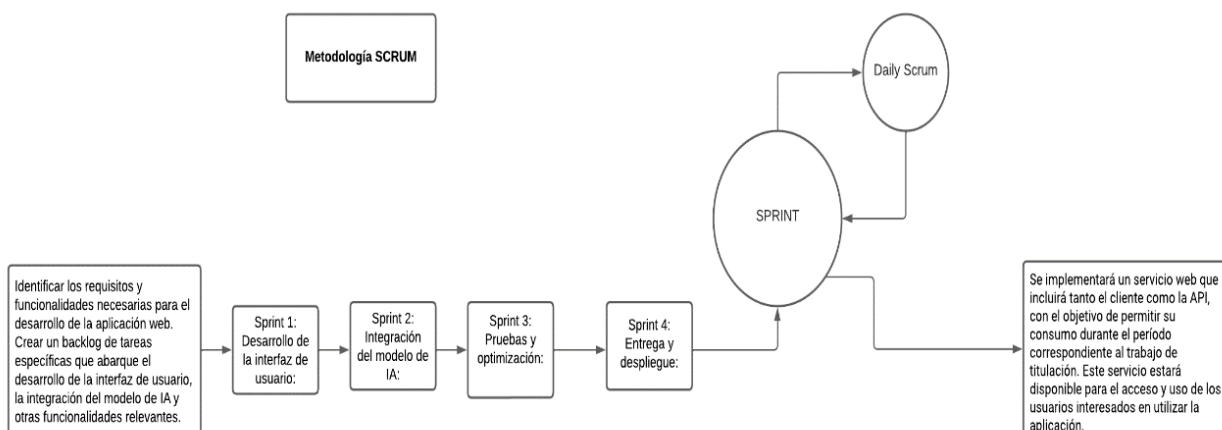
Gráfico de la metodología CRIP-DM



Fuente: Elaboración Propia

Figura 4

Gráfico de la metodología SCRUM



Fuente: Elaboración propia

Justificación

La justificación de este proyecto se basa en la necesidad de abordar el problema del estrés en la población joven universitaria desde una perspectiva tecnológica. El estrés se ha convertido en una preocupación significativa en la sociedad actual, especialmente entre los jóvenes que se enfrentan a múltiples presiones académicas, sociales y personales. Este problema afecta negativamente su bienestar general, rendimiento académico y calidad de vida. En este contexto, el desarrollo de un software basado en inteligencia artificial para la detección temprana de estrés tiene un alto potencial de impacto positivo. Este enfoque se

alineada con varios ODS, como el ODS 3 (Salud y bienestar), ODS 4 (Educación de calidad) y ODS 9 (Industria, innovación e infraestructura). Al proporcionar una herramienta tecnológica que permita la identificación temprana del estrés, se promueve la salud mental y el bienestar de los estudiantes, mejorando su salud en general y su capacidad para enfrentar los desafíos de manera efectiva. Además, el desarrollo de este software implica la utilización de tecnología innovadora y la creación de una infraestructura tecnológica adecuada, lo que contribuye al ODS 9 al fomentar la industria y la innovación en el campo de la salud mental. Asimismo, este proyecto puede integrarse como un recurso dentro de la universidad al igual que dentro de las agendas zonales al enfocarse en mejorar la calidad de vida de los jóvenes.

Justificación Tecnológica

La presente investigación tiene como objetivo principal desarrollar una prueba preventiva de detección de estrés para su uso por parte de los estudiantes de la Universidad Técnica del Norte (UTN). Esta iniciativa busca brindar una herramienta adicional que ayude a identificar y abordar el estrés de manera temprana, proporcionando apoyo tanto al personal académico como a los propios estudiantes.

La creación de esta prueba preventiva supone un impacto significativo tanto a nivel económico como social. En términos económicos, la detección temprana del estrés puede contribuir a reducir los costos asociados con la salud mental y el rendimiento académico disminuido. Asimismo, a nivel social, la implementación de esta prueba busca fomentar un entorno universitario más saludable y propicio para el bienestar de los estudiantes.

La adopción de esta solución tecnológica permitirá a la UTN contar con una herramienta valiosa que complementará los servicios existentes de apoyo psicológico y académico. Además, brindará a los estudiantes la oportunidad de acceder a recursos adicionales y de recibir una atención más personalizada en relación con su nivel de estrés. En última instancia, se espera que esta prueba preventiva contribuya a mejorar la calidad de vida y el rendimiento académico de los estudiantes de la UTN.

Justificación de salud

La justificación de este proyecto se basa en la importancia de abordar la salud mental de los estudiantes de la Universidad Técnica del Norte (UTN). El estrés es un problema común entre los estudiantes y puede tener un impacto significativo en su bienestar y rendimiento académico. Por lo tanto, es fundamental desarrollar estrategias preventivas y herramientas de detección temprana para promover la salud mental y prevenir posibles consecuencias negativas.

La implementación de una prueba preventiva de detección de estrés utilizando tecnologías de inteligencia artificial brinda la oportunidad de intervenir de manera temprana

y proporcionar apoyo adecuado a los estudiantes. Al detectar el estrés de manera oportuna, se pueden implementar estrategias de manejo y ofrecer recursos de apoyo, como terapia o asesoramiento, para ayudar a los estudiantes a manejar el estrés de manera saludable.

Además, al mejorar la salud mental de los estudiantes, se espera que haya un impacto positivo en su bienestar general y en su calidad de vida. Esto puede contribuir a la reducción de enfermedades relacionadas con el estrés, como la ansiedad y la depresión, y promover un ambiente universitario más saludable y favorable para el aprendizaje.

Capítulo I

Marco Teórico

1.1 Identificación de Estrés

1.1.1 Estrés

El estrés, entendido como un estado mental caracterizado por una tensión nerviosa intensa y prolongada, acompañada de una elevada ansiedad, puede dividirse en diversas categorías. El estrés psicológico es provocado por estímulos emocionales o perceptivos, como la pérdida de afecto o situaciones amenazantes. El estrés social está vinculado a restricciones culturales o cambios en los valores. El estrés económico se refleja en dificultades financieras o desempleo. Por otro lado, el estrés fisiológico surge de agresiones químicas o infecciones. Finalmente, el estrés psicosocial está influenciado por la percepción del individuo y su capacidad para afrontar situaciones estresantes. (Provincial Salud & At Integ Mujer María Elena Bairero Aguilar, 2017).

1.1.2 Mediciones del estrés

Existen varios instrumentos autoadministrados disponibles para medir el estrés percibido en contextos clínicos e investigaciones epidemiológicas. Uno de los más reconocidos es la Escala de Estrés Percibido (EEP), que se utiliza para evaluar la respuesta psicológica general ante estresores. La EEP ha sido sometida a evaluación psicométrica en diversos ámbitos y poblaciones, resultando en varias versiones de la herramienta. Además de la versión original de 14 ítems (EEP-14), existen otras versiones más refinadas, entre las que destacan la EEP-10 y la EEP-4, con traducciones disponibles en varios idiomas, incluyendo el español (Campo-Arias et al., 2014).

1.1.3 Escala de Estrés Percibido (EEP)

Esta escala es un cuestionario de autoevaluación diseñado para medir el nivel de estrés percibido en el último mes. Consiste en 14 afirmaciones con una escala de respuesta de cinco puntos (0 = nunca, 1 = casi nunca, 2 = de vez en cuando, 3 = a menudo, 4 = muy a menudo). Para calcular la puntuación total, se invierten las puntuaciones de ciertos ítems (4, 5, 6, 7, 9, 10 y 13) en el siguiente sentido: 0=4, 1=3, 2=2, 3=1 y 4=0, luego se suman todas las respuestas. Una puntuación más alta indica un mayor nivel de estrés percibido (Ramos & Fernandez, 2019).

1.1.4 Escala DASS-21 (Depression Anxiety and Stress Scale - 21)

Esta herramienta psicométrica diseñada para evaluar y medir los niveles de depresión, ansiedad y estrés en individuos. Consta de 21 ítems que se distribuyen en tres subescalas, cada una con siete ítems específicos: depresión (ítems 3, 5, 10, 13, 16, 17 y 21),

ansiedad (ítems 2, 4, 7, 9, 15, 19 y 20) y estrés (ítems 1, 6, 8, 11, 12, 14 y 18). Los participantes deben calificar cada ítem en una escala de 0 a 3, donde 0 significa "No me ha ocurrido" y 3 indica "Me ha ocurrido mucho, o la mayor parte del tiempo", reflejando la frecuencia con que han experimentado cada afirmación durante la semana anterior.

La evaluación se realiza sumando las puntuaciones de los ítems correspondientes a cada subescala para obtener una medida específica de depresión, ansiedad y estrés. Además, se puede calcular una puntuación general sumando las puntuaciones de todos los ítems, proporcionando un indicador global de síntomas emocionales.

Los puntos de corte utilizados para interpretar las puntuaciones son los siguientes:

Depresión:

- 5-6: leve
- 7-10: moderada
- 11-13: severa
- 14 o más: extremadamente severa

Ansiedad:

- 4: leve
- 5-7: moderada
- 8-9: severa
- 10 o más: extremadamente severa

Estrés:

- 8-9: leve
- 10-12: moderado
- 13-16: severo
- 17 o más: extremadamente severo

El DASS-21, validado en diversos contextos, incluyendo la población colombiana, es ampliamente utilizado tanto en investigaciones como en prácticas clínicas para identificar y cuantificar la sintomatología emocional, facilitando la intervención temprana y el tratamiento adecuado (Antony et al., 1998).

1.1.5 Escala GAD-7 (Generalized Anxiety Disorder 7-item Scale)

Esta herramienta de evaluación psicológica utilizada para identificar y medir la gravedad de los síntomas de trastorno de ansiedad generalizada (TAG). Este instrumento consta de siete ítems que evalúan la frecuencia de diversas molestias asociadas con la ansiedad durante las últimas dos semanas. Los participantes deben calificar cada ítem en una

escala de 0 a 3, donde 0 significa "Ningún día", 1 "Varios días", 2 "Más de la mitad de los días" y 3 "Casi todos los días".

Los ítems del GAD-7 son los siguientes:

1. Sentirse nervioso(a), ansioso(a) o con los nervios de punta.
2. No ser capaz de parar o controlar la preocupación.
3. Preocuparse demasiado por diferentes motivos.
4. Tener dificultad para relajarse.
5. Sentirse tan inquieto(a) que no se puede quedar quieto(a).
6. Molestarse o irritarse fácilmente.
7. Tener miedo de que algo terrible pueda pasar.

La puntuación total se obtiene sumando las calificaciones de cada ítem, con un rango que va de 0 a 21. La interpretación de las puntuaciones se realiza de la siguiente manera:

- 0-4: Mínima ansiedad.
- 5-9: Ansiedad leve.
- 10-14: Ansiedad moderada.
- 15-21: Ansiedad severa.

El GAD-7 fue desarrollado por los doctores Robert L. Spitzer, Janet B.W. Williams, Kurt Kroenke, ha sido validado en diversas investigaciones y entornos clínicos. Este instrumento es ampliamente utilizado tanto en la práctica clínica como en estudios de investigación para la detección y evaluación de la ansiedad, facilitando la identificación temprana y la intervención adecuada para los individuos que presentan síntomas de ansiedad generalizada (Robert L. Spitzer et al., 2017).

1.1.6 Escala de Reajuste Psicosocial de Thomas Holmes y Richard Rahe

Este instrumento fue diseñado para medir el nivel de estrés asociado a diferentes eventos de la vida que una persona puede experimentar en un año. Esta escala evalúa 43 acontecimientos que, según la investigación de los autores, están asociados con diversos grados de alteración y estrés.

Instrucciones:

Los individuos deben anotar el valor correspondiente a cada situación que hayan experimentado durante el último año y sumar el total obtenido. Cada acontecimiento tiene un valor asignado que refleja su impacto relativo en términos de estrés.

Lista de acontecimientos y valores asignados:

Muerte del cónyuge - 100

Divorcio - 73
Separación - 65
Privación de la libertad - 63
Muerte de un familiar próximo - 63
Enfermedad o incapacidad graves - 53
Matrimonio - 50
Perder el empleo - 47
Reconciliación de la pareja - 45
Jubilación - 45
Enfermedad de un pariente cercano - 44
Embarazo - 40
Problemas sexuales - 39
Llegada de un nuevo miembro a la familia - 39
Cambios importantes en el trabajo - 39
Cambios importantes a nivel económico - 38
Muerte de un amigo íntimo - 37
Cambiar de empleo - 36
Discusiones con la pareja (cambio significativo) - 35
Pedir una hipoteca de alto valor - 31
Hacer efectivo un préstamo - 30
Cambio de responsabilidades en el trabajo - 29
Un hijo/a abandona el hogar (matrimonio, universidad) - 29
Problemas con la ley - 29
Logros personales excepcionales - 28
La pareja comienza o deja de trabajar - 26
Se inicia o se termina el ciclo de escolarización - 26
Cambios importantes en las condiciones de vida - 25
Cambio en los hábitos personales - 24
Problemas con el jefe - 23
Cambio en el horario o condiciones de trabajo - 20
Cambio de residencia - 20
Cambio a una escuela nueva - 20
Cambio en la forma o frecuencia de las diversiones - 19
Cambio en la frecuencia de las actividades religiosas - 19

Cambio en las actividades sociales - 18
Pedir una hipoteca o préstamo menor - 17
Cambios en los hábitos del sueño - 16
Cambios en el número de reuniones familiares - 15
Cambio en los hábitos alimentarios - 15
Vacaciones - 15
Navidades - 12
Infracciones menores de la ley - 11
Valoración:

La puntuación total se expresa en unidades de cambio vital (UCV). Una persona que acumule 200 o más UCV en un solo año está en riesgo de experimentar trastornos psicosomáticos. Según la investigación de Holmes y Rahe, un mayor puntaje se asocia con una mayor incidencia de trastornos relacionados con el estrés (Holmes Thomas & Rahe Richard, 1976) .

1.1.7 Estrés en estudiantes universitarios

Los principales desencadenantes de estrés en los estudiantes son la carga excesiva de tareas y trabajos escolares. Según una encuesta realizada en estudiantes de la universidad Tecnológico de Monterrey, el 25.6% de los estudiantes siempre sienten esta sobrecarga, seguido por el 37.2% que la experimentan casi siempre. En cuanto a las evaluaciones por parte de los profesores, el 29.5% de los encuestados afirman que casi siempre les preocupan, seguido por el 24.4% que las consideran una preocupación constante. Respecto al tiempo limitado para realizar los trabajos, el 33.3% de los estudiantes se estresan casi siempre por esta razón, seguidos por el 28.2% que siempre se ven afectados por la presión del tiempo (Mendoza & Ortega, 2010).

1.1.8 Estrés académico

Para una institución educativa, es crucial comprender los niveles de estrés académico en sus estudiantes, ya que este se relaciona con problemas de salud como depresión, enfermedades crónicas y cardíacas, así como fallas en el sistema inmune. Detectar y abordar estos problemas de salud es prioritario para prevenir complicaciones y nuevas afecciones. El ingreso a la universidad marca el inicio de situaciones estresantes, como la separación familiar, la incorporación al mundo laboral y la adaptación a nuevos entornos, lo que, combinado con responsabilidades académicas y personales, puede generar una carga emocional significativa en los estudiantes universitarios, iniciando las causas de estrés en los mismos (Palma, 2015).


1.2 Hardware de reconocimiento de biométricos del estrés

1.2.1 Sensores biométricos de medición del estrés

Havamoasa Muscle Signal Sensor EMG (Sensor muscular) el dispositivo mide la activación muscular mediante potencial eléctrico, conocida como electromiografía (EMG), ha sido tradicionalmente empleada en la investigación médica y en el diagnóstico de trastornos neuromusculares. Sin embargo, con el avance de microcontroladores cada vez más pequeños, pero más potentes y circuitos integrados, los circuitos y sensores de EMG se han incorporado a prótesis, robótica y otros sistemas de control (Adcancer Technologies, 2013).

Figura 5

Sensor EMG




Fuente:(Adcancer Technologies, 2013)

ESP32 es una placa de desarrollo de bajo tamaño y nivel de entrada que forma parte de la serie ESP32. Esta placa cuenta con un amplio conjunto de periféricos. El esquema de pines integrado del ESP32 está optimizado para facilitar el prototipado sin complicaciones utilizado para la recepción y envío de datos de los sensores colocados (espressif, 2023).

Figura 6

ESP32 placa de desarrollo




Fuente: (espressif, 2023)

Sensor de Pulso Original es un sensor que permite monitorear el ritmo cardíaco y proporcionar retroalimentación biológica de manera creativa. Es especialmente útil para medir el estrés. Este sensor se integra fácilmente con placas de desarrollo como Arduino, ESP32 y micro:bit, lo que lo hace accesible para estudiantes, artistas y desarrolladores. Proporciona datos precisos sobre el ritmo cardíaco, lo que permite a los usuarios explorar y entender su respuesta fisiológica al estrés (pulsesensor, 2023).

Figura 7

Sensor de pulso



Fuente:(pulsesensor, 2023)

MQ-3 Detector de Alcohol es un sensor electroquímico que detecta principalmente alcohol y otros gases en el ambiente. Su diseño permite una conexión sencilla con tarjetas de desarrollo mediante dos salidas: analógica y digital. Este sensor puede ser utilizado para medir la frecuencia respiratoria al exhalar. Al analizar los gases exhalados, proporciona información valiosa sobre la frecuencia y los patrones de la respiración, lo que resulta útil para evaluar la respuesta fisiológica ante situaciones de estrés (uelectronics, 2024).

Figura. 8

Sensor de CO2 MQ-3



Fuente:(uelectronics, 2024)

El sensor de temperatura DS18B20 con sonda intercambiable es una opción práctica para medir la temperatura corporal. Su diseño permite una conexión sencilla a microcontroladores gracias a la resistencia de pull-up integrada en el adaptador. Este sensor es adecuado para su uso en aplicaciones de monitoreo de temperatura corporal, proporcionando lecturas precisas en un rango de -55 a 125 °C. Es especialmente útil para aplicaciones médicas y de salud, permitiendo la medición precisa y rápida de la temperatura del cuerpo humano. Con cables de salida claramente marcados (DATA, VCC, GND), es fácil de instalar y utilizar para mediciones de temperatura corporal en tiempo real (Gikfun, 2024).

Figura 9

Sensor de temperatura




Fuente:(Gikfun, 2024)

La pantalla LCD con módulo I2C, eficiente y precisa, muestra datos biométricos como la frecuencia cardíaca y la temperatura corporal con claridad. Perfecta para dispositivos de monitoreo de salud, su fácil conexión y bajo consumo de energía la hacen ideal para aplicaciones portátiles y de salud personalizada (naylampmechatronics, 2015).

Figura 10

Pantalla LCD I2C



Fuente: (naylampmechatronics, 2015)

El pulsador de 4 pines es un interruptor electromecánico que se activa mediante presión. Tiene cuatro pines para una conexión segura a placas de circuito o microcontroladores. Sirve para aplicaciones donde se requiere una entrada de usuario simple y rápida, como encendido/apagado o selección de opciones (megatronica, 2024).

Figura 11

Pulsador de 4 pines



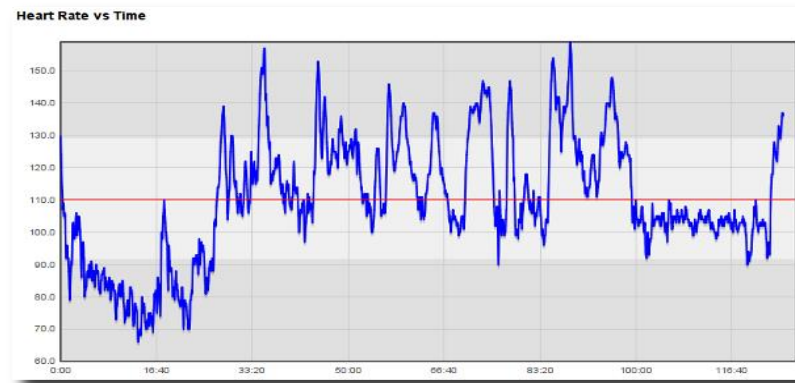
Fuente:(megatronica, 2024)

1.2.2 Señales biométricas de medición del estrés

La HR (*Heart Rate*) se deriva de la forma de onda BVP, buscando máximos locales consecutivos. La actividad simpática aumentada resulta en un incremento de la frecuencia cardíaca. Además, la HRV (variabilidad del ritmo cardíaco) y el Electrocardiograma también pueden ser indicadores en situaciones estresantes (Ruiz et al., 2020).

Figura 12

Señal frecuencia cardiaca

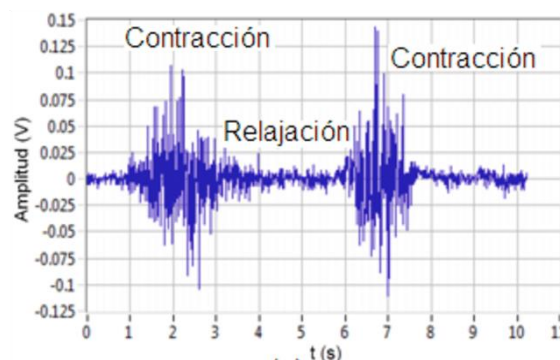


Fuente: (GPSLog, 2019)

El EMG (Electromiograma) mide la actividad eléctrica de los músculos, que tiende a aumentar con el estrés, mostrando mayor actividad de espasmos (Palacio et al., 2021).

Figura 13

Señal EMG




Fuente:(Rosa, 2020)

La Temp. (temperatura corporal y de la piel) se altera en situaciones de estrés (Ruiz et al., 2020).

Figura 14

Señal de temperatura corporal




Fuente:(Christian, 2017)

La BR (*Breathing rate*) indica el número de respiraciones por unidad de tiempo, que se ve afectado bajo estrés (Ruiz et al., 2020).

Figura 15

Señal de frecuencia respiratoria



Fuente:(Researchgate, 2020)

1.3 Tecnologías de inteligencia artificial con interfaz web

1.3.1 Lenguaje de programación de la aplicación fronted web detección de estrés

JavaScript, es un lenguaje de codificación, es mayormente utilizado para la creación de sitios web interactivos. Estos sitios, llamados dinámicos, presentan características como efectos de texto, animaciones y acciones que responden a la interacción del usuario, como hacer clic en botones, así como la visualización de mensajes emergentes. Desde el punto de vista técnico, JavaScript opera como un lenguaje interpretado, lo que significa que no requiere compilación previa para su ejecución. Esto se traduce en la capacidad de probar

programas escritos en JavaScript directamente en cualquier navegador, sin necesidad de procesos adicionales de transformación (Eguíluz Pérez, 2009).

1.3.2 librerías de desarrollo fronted para páginas web

ReactJS, una biblioteca de JavaScript desarrollada por Facebook es fundamental en el desarrollo web moderno gracias a su enfoque en la creación de interfaces de usuario (UI) interactivas y dinámicas mediante componentes reutilizables. Su paradigma basado en componentes facilita el modularidad y el mantenimiento del código, mientras que su uso del "Virtual DOM" permite actualizaciones eficientes de la interfaz, mejorando el rendimiento de la aplicación. ReactJS cuenta con un ecosistema activo que incluye herramientas como React Router, Redux y React Native, lo que la convierte en una opción popular para desarrolladores que buscan construir aplicaciones web y móviles eficientes y escalables (hostinger, 2023).

1.3.3 Lenguaje de programación para entrenar el modelo de Inteligencia Artificial y el desarrollo del backend de la aplicación web

Python es un lenguaje de programación ampliamente utilizado en diversos ámbitos, como el desarrollo de aplicaciones web, software, ciencia de datos y aprendizaje automático (ML). Su popularidad se debe a su eficiencia, simplicidad para aprender y su capacidad para ejecutarse en múltiples plataformas. Al ser de código abierto, Python es accesible para todos y se integra fácilmente con diferentes sistemas, lo que acelera el proceso de desarrollo (Python Software Foundation, 2024).

1.3.4 Framework de desarrollo backend para la aplicación web

Django es un framework web de alto nivel y código abierto, desarrollado en Python, que agiliza la creación de aplicaciones web complejas. Su enfoque en el desarrollo rápido y limpio lo hace popular entre los desarrolladores. Con un sistema MVC implícito, un ORM integrado y un potente administrador de Django, simplifica tareas como la gestión de datos y la creación de interfaces de usuario dinámicas. Además, proporciona características de seguridad integradas y una estructura organizativa que fomenta la escalabilidad y el mantenimiento a largo plazo. En resumen, Django es una herramienta esencial para el desarrollo eficiente de aplicaciones web robustas (django, 2024).

1.3.5 Base de datos para el guardado de los datos de los biométricos

PostgreSQL, comúnmente conocido como "Post-GRES", es una base de datos de código abierto muy valorada por su fiabilidad, flexibilidad y adherencia a estándares técnicos abiertos. A diferencia de otros sistemas de gestión de bases de datos relacionales, PostgreSQL admite tanto tipos de datos relacionales como no relacionales. Esta

característica la posiciona como una de las opciones más completas, estables y maduras en el mercado de bases de datos relacionales en la actualidad. Su capacidad para adaptarse a diversos tipos de datos la convierte en una elección sólida para aplicaciones que requieren flexibilidad y consistencia en su almacenamiento de información (IBM, 2024).

1.4 Modelo de Inteligencia artificial para la clasificación de estrés en estudiantes

1.4.1 Normalización de los datos

La normalización es un proceso utilizado en bases de datos para organizar los datos de manera eficiente y evitar la redundancia. Consiste en estructurar la información en tablas relacionadas, siguiendo reglas como la eliminación de la duplicación de datos y la garantía de la integridad referencial. Al aplicar la normalización, se reducen los riesgos de inconsistencias y se facilita la gestión de la información. Este proceso se divide en diferentes formas, llamadas formas normales, desde la primera hasta la tercera forma normal y más allá, cada una abordando distintos aspectos de la organización de datos (Álvarez Núñez et al., 2022).

1.4.2 Segmentación temporal de los datos


La segmentación temporal de los datos implica dividir la información en intervalos de tiempo definidos para su análisis y gestión eficiente. Este enfoque permite organizar y comprender mejor conjuntos de datos temporales, facilitando la detección de patrones, tendencias y eventos relevantes en diferentes períodos. Al igual que la segmentación de video, donde se divide un video en clips más pequeños para su análisis, la segmentación temporal de datos se centra en la partición de datos en tramos temporales coherentes, lo que ayuda a mejorar la comprensión y la toma de decisiones basadas en el tiempo (Úbeda Romero et al., 2020).

1.4.3 Las Redes Neuronales Artificiales

Se refieren a sistemas de procesamiento de datos que se reconocen como un modelo matemático para computación. Su uso es común en varios contextos teóricos y prácticos, y este trabajo se enfoca particularmente en aquellas empleadas en la clasificación de patrones. En su estructura, las Redes Neuronales Artificiales (RNA) se componen de unidades llamadas neuronas artificiales, las cuales están interconectadas (E. Sánchez & Rodríguez, 2022).

Figura 16

Representación de una RNA



Fuente:(E. Sánchez & Rodríguez, 2022)

1.5 Machine learning

El aprendizaje automático aplicado al estrés en estudiantes implica la utilización de algoritmos y técnicas computacionales para identificar patrones y factores asociados con el estrés estudiantil. A través de la recopilación de datos provenientes de diversas fuentes, como encuestas, registros académicos y dispositivos portátiles, se pueden desarrollar modelos predictivos que ayuden a detectar señales tempranas de estrés. Estos modelos analizan factores como el rendimiento académico, la actividad física, los patrones de sueño y el uso de tecnología, con el fin de proporcionar recomendaciones personalizadas y recursos de apoyo a los estudiantes. Además, el aprendizaje automático contribuye a la investigación sobre los determinantes del estrés estudiantil y a la implementación de intervenciones preventivas y de apoyo (J. Sánchez, 2019).

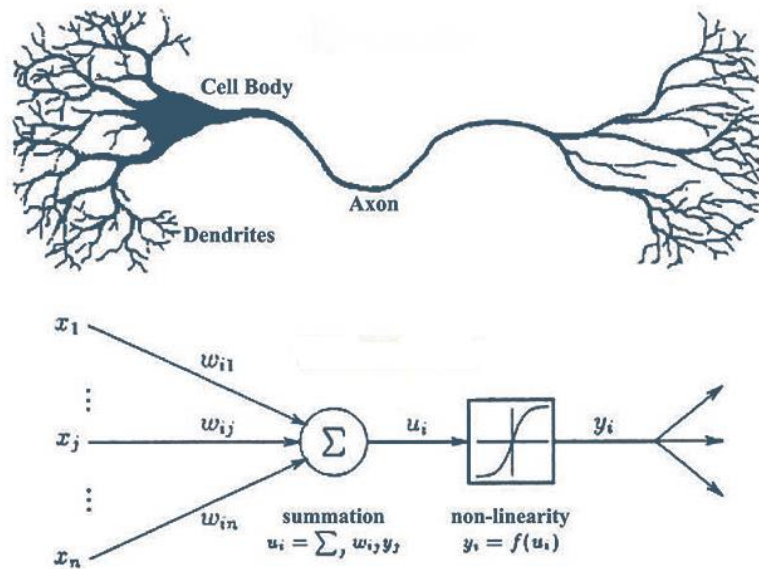
1.5.1 Arquitectura de red neuronal profunda (RNA)

En el ámbito de la detección del estrés a través de datos biométricos numéricos, se han utilizado redes neuronales artificiales (RNA) para el reconocimiento de patrones. En este contexto, los datos biométricos se procesan mediante RNA entrenadas previamente, donde las características relevantes son aprendidas por las neuronas artificiales. Los usuarios ingresan los datos biométricos, como frecuencia cardíaca o niveles de cortisol, y la red neuronal procesa esta información, proporcionando una respuesta de reconocimiento del estado de estrés. Sin embargo, este enfoque enfrenta desafíos similares en términos de la cantidad y diversidad de datos necesarios para un entrenamiento efectivo de la red. Para

abordar estas limitaciones, se ha explorado el uso del aprendizaje profundo o Deep Learning, una técnica que permite analizar y clasificar datos numéricos con mayor precisión mediante redes neuronales profundas (Pasquel & Pamela, 2018).

Figura 17

Red Neuronal Profunda




Fuente:(McCulloch & Pitts, 2019)

1.5.2 La capa de salida de una neurona con una función de activación lineal

La relevancia de este proceso radica en que, durante el entrenamiento de la red neuronal, las neuronas de las capas intermedias se organizan de manera autónoma para aprender a reconocer diversas características del conjunto total de datos de entrada. Tras el entrenamiento, cuando se presenta un patrón de entrada que puede contener ruido o estar incompleto, las neuronas de la capa oculta de la red responderán con una señal activa si la nueva entrada coincide con alguna de las características que han aprendido durante el entrenamiento. Por el contrario, estas neuronas tienen una tendencia a inhibir su respuesta si el patrón de entrada carece de las características para las cuales fueron entrenadas. Una red neuronal típica, como la de retropropagación (Backpropagation), se estructura con tres capas: una de entrada con x neuronas, una de salida con z neuronas, y una capa oculta con m neuronas. Además, en relación con esto, se destaca la importancia de la capa de salida de una neurona que emplea una función de activación lineal (Vargas & Salazar, 2004).

Figura 18

Función neuronal



Fuente:(AWS, 2023b)

1.5.3 Función de pérdida error cuadrático medio (MSE)

La función de costos en predicción estadística es fundamental para evaluar la calidad de los pronósticos de un modelo, estableciendo una relación entre los resultados observados y los pronosticados. Representada como $L(y_{t+h}, f_{t+h|t}, z_t)$, donde y_{t+h} es el valor observado en el tiempo $t+h$, $f_{t+h|t}$ es el pronóstico en el tiempo t , y z_t es información adicional en t . Es crucial definir restricciones precisas para la función de costos; por ejemplo, debe existir si hay errores de pronóstico. El error cuadrático medio (MSE) es una medida común de la función de costos, calculada como la media de los cuadrados de las diferencias entre los valores reales y pronosticados. $MSE = (1/n) \sum (y_i - \hat{y}_i)^2$, donde y_i son los valores reales y \hat{y}_i son los pronosticados. Además, otras restricciones como la normalización, positividad, simetría, homogeneidad, convexidad, continuidad y diferenciabilidad deben cumplirse para garantizar la coherencia y aplicabilidad de la función de costos en la predicción estadística. Estas restricciones aseguran que la función de costos sea adecuada y confiable para evaluar la precisión de los modelos de pronóstico (Andrés Jalil & Misas, 2007).

1.5.4 Entrenar el modelo utilizando un conjunto diverso y representativo de datos de diferentes lugares para mejorar la generalización.

El entrenamiento del modelo es un proceso fundamental en el desarrollo de sistemas de inteligencia artificial y aprendizaje automático. Destaca la importancia de utilizar un conjunto de datos diverso y representativo durante este proceso. Al entrenar un modelo con datos provenientes de diferentes lugares, se busca mejorar su capacidad de generalización,

es decir, su capacidad para realizar predicciones precisas sobre datos no vistos previamente. Esto se logra al exponer al modelo a una variedad de escenarios y situaciones, lo que le permite capturar una amplia gama de patrones y características presentes en los datos del mundo real. Además, al utilizar un conjunto de datos diverso y representativo, se reduce el riesgo de sesgos y sobreajustes, ya que el modelo aprende a extraer características relevantes de manera más completa y equilibrada (Erazo & Galarza, 2023).


1.6 Arquitectura SVM (Super vector machine)

Las Máquinas de Vectores de Soporte (SVM) son un modelo de aprendizaje supervisado utilizado para clasificación y regresión. SVM busca encontrar el hiperplano óptimo que mejor separa las clases en un espacio de características, maximizando el margen entre ellas. Utiliza vectores de soporte, muestras cercanas al límite de decisión, para definir el hiperplano. SVM es efectivo en conjuntos de datos de alta dimensionalidad y puede manejar tanto datos lineales como no lineales a través del uso de funciones de kernel. Es robusto frente al sobreajuste y es ampliamente utilizado en diversas aplicaciones de aprendizaje automático (Singh et al., 2016).

El algoritmo SVM es conocido por su habilidad para encontrar el hiperplano que mejor separa las clases en el espacio de características, maximizando el margen entre las clases. Se entrenaron varios modelos de SVM con diferentes configuraciones de parámetros, incluyendo el tipo de kernel (lineal, polinómico, RBF) y el parámetro de regularización.

Figura 19

Arquitectura SVM



Fuente:(Wang et al., 2024)


1.7 Arquitectura Random forest

Random Forest es un algoritmo de aprendizaje supervisado utilizado para clasificación y regresión. Consiste en la construcción de múltiples árboles de decisión

durante el entrenamiento y la combinación de sus resultados para obtener una predicción más precisa y estable. Cada árbol se construye utilizando un subconjunto aleatorio de características y se basa en la votación de múltiples árboles para la clasificación o el promedio para la regresión. Esto lo hace resistente al sobreajuste y adecuado para conjuntos de datos grandes y complejos. Random Forest es ampliamente utilizado en diversas aplicaciones de aprendizaje automático debido a su robustez y eficacia (Pérez et al., 2020).

Figura 20

Random Forest



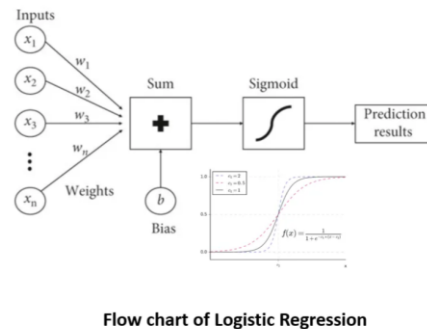

Fuente:(Pérez et al., 2020).

1.8 Arquitectura XGBoost

XGBoost es un algoritmo de aprendizaje automático basado en árboles de decisión, optimizado para mejorar la precisión y eficiencia de las predicciones. Se entrenaron varios modelos de XGBoost con diferentes configuraciones de parámetros, incluyendo el número de estimadores, la tasa de aprendizaje, la profundidad máxima de los árboles y la proporción de muestras utilizadas.

Figura 21

Arquitectura XGBoost



Fuente:(Krabs, 2024)


1.9 Metodologías utilizadas para el desarrollo web como para el desarrollo del modelo de inteligencia artificial.

1.9.1 Metodología SCRUM

Scrum es una metodología ágil de desarrollo de software que se enfoca en la entrega iterativa e incremental de productos de alta calidad. En Scrum, los proyectos se dividen en ciclos de trabajo llamados "sprints", que suelen tener una duración de 2 a 4 semanas. Cada sprint comienza con una reunión de planificación donde se seleccionan las tareas a abordar y se establecen los objetivos a alcanzar. Durante el sprint, el equipo se reúne diariamente en la "reunión diaria" o "daily scrum" para discutir el progreso y cualquier impedimento que pueda surgir. Al final de cada sprint, se lleva a cabo una revisión donde se presenta el trabajo realizado y se recopila retroalimentación, seguida de una retrospectiva para analizar qué se hizo bien, qué se podría mejorar y cómo hacerlo en el futuro. Scrum se basa en la colaboración, la transparencia y la adaptabilidad, promoviendo la comunicación continua entre los miembros del equipo y fomentando la flexibilidad para adaptarse a los cambios en los requisitos del proyecto (Manuel, 2012).

Figura 22

Metodología SCRUM




Fuente:(Manuel, 2012)

1.9.2 Metodología CRISP-DM

CRISP-DM (Cross Industry Standard Process for Data Mining) es un modelo de proceso de minería de datos que describe cómo los expertos en este campo abordan los problemas específicos. Implementar tecnología en un entorno empresarial requiere una metodología definida, a menudo derivada de la experiencia y de los procedimientos estándar bien establecidos. Para proyectos de implementación de minería de datos, una metodología ampliamente respaldada por empresas privadas y organismos públicos es CRISP-DM. Aunque ha experimentado una ligera disminución en su uso en los últimos años, sigue siendo la metodología más utilizada según encuestas recientes. CRISP-DM consta de seis fases, algunas de las cuales son bidireccionales, lo que significa que se puede retroceder a una fase anterior para su revisión. Por lo tanto, la secuencia de fases no necesariamente sigue un orden lineal de la primera a la última (Galán & Castro, 2015).

Figura 23

Metodología CRISP-DM



Fuente:(Galán & Castro, 2015)

1.10 Trabajos relacionados

1.10.1 Stress-Lysis: A DNN-Integrated Edge Device for stress Level Detection in the IoMT

El estrés psicológico afecta significativamente los parámetros fisiológicos de una persona, influyendo negativamente en su bienestar general. La exposición prolongada al estrés puede tener efectos nocivos que podrían requerir tratamientos costosos. En individuos diagnosticados con trastorno límite de la personalidad o esquizofrenia, los niveles agudos de estrés pueden ser extremadamente peligrosos, llegando incluso a ser letales.

En el contexto de la atención médica inteligente, un artículo propone un sistema innovador basado en el aprendizaje profundo, denominado Stress-Lysis. Este sistema está diseñado para monitorear los niveles de estrés en los individuos mediante la medición de la temperatura corporal, la tasa de movimiento y el sudor durante la actividad física. El sistema Stress-Lysis ha sido entrenado utilizando un conjunto de datos que incluye 26,000 muestras, logrando una precisión de hasta el 99.7%. Los datos recopilados se transmiten y almacenan en la nube, lo que facilita el monitoreo en tiempo real de los niveles de estrés, ayudando a reducir el riesgo de muerte y los costos asociados con tratamientos médicos.

El sistema propuesto tiene la capacidad de producir resultados con una precisión general del 98.3% al 99.7%, es sencillo de implementar y su costo es moderado. Además de ayudar a los individuos a mantenerse conscientes de su nivel de estrés proporcionando retroalimentación inmediata para fomentar cambios en el estilo de vida hacia hábitos más saludables, Stress-Lysis también juega un papel significativo en la tecnología moderna al permitir la computación en dispositivos de borde. Esta capacidad de procesamiento cercano a los sensores reduce el tráfico de comunicación y mejora la respuesta del sistema de Internet de las Cosas Médicas (IoMT), contribuyendo notablemente al avance del cuidado de la salud inteligente (Rachakonda et al., 2019).

1.10.2 Introducing WESAD, a Multimodal Dataset for Wearable stress and Affect Detection

El reconocimiento de afectos tiene como objetivo detectar el estado afectivo de una persona basándose en observables, con el propósito de mejorar la interacción humano-computadora. Se sabe que el estrés a largo plazo tiene graves implicaciones para el bienestar, lo que exige sistemas de monitoreo del estrés continuos y automatizados. Sin embargo, la comunidad de computación afectiva carece de conjuntos de datos estándar comúnmente utilizados para la detección de estrés mediante dispositivos portátiles que a) proporcionen datos multimodales de alta calidad y b) incluyan múltiples estados afectivos. Por lo tanto, presentamos WESAD, un nuevo conjunto de datos de acceso público para la detección de estrés y afecto con dispositivos portátiles. Este conjunto de datos multimodal incluye datos fisiológicos y de movimiento, registrados tanto de un dispositivo de muñeca como de un dispositivo de pecho, de 15 sujetos durante un estudio de laboratorio. Las modalidades de sensores incluidas son: pulso de volumen sanguíneo, electrocardiograma, actividad electrodermal, electromiograma, respiración, temperatura corporal y aceleración en tres ejes. Además, el conjunto de datos cierra la brecha entre estudios de laboratorio previos sobre estrés y emociones, al contener tres diferentes estados afectivos (neutral, estrés, diversión). Asimismo, el conjunto de datos incluye informes subjetivos de los sujetos, obtenidos mediante varios cuestionarios establecidos. Además, se crea un benchmarking utilizando características bien conocidas y métodos estándar de aprendizaje automático. Considerando el problema de clasificación de tres clases (línea base vs. estrés vs. diversión), se lograron precisiones de clasificación de hasta el 80%. En el caso binario (estrés vs. no estrés), se alcanzaron precisiones de hasta el 93%. Finalmente, se proporciona un análisis detallado y una comparación de las dos ubicaciones de los dispositivos (pecho vs. muñeca), así como de las diferentes modalidades de sensores (Schmidt et al., 2018).

1.10.3 Thermal Comfort and Stress Recognition in Office Environment

El estrés laboral y la incomodidad térmica son algunos de los obstáculos que los trabajadores de oficina enfrentan diariamente. Estos empleados experimentan un estrés laboral periódico debido a la duración extensa y la naturaleza mentalmente desafiante del trabajo. Al mismo tiempo, las tecnologías actuales para proporcionar confort térmico son ineficientes y consumen una gran cantidad de energía. En trabajos anteriores, propusimos un sistema eficiente para el suministro de confort térmico basado en la variabilidad de la frecuencia cardíaca (VFC) de una persona. Sin embargo, dado que el estrés laboral también puede afectar la VFC de una persona, este estudio investiga la posibilidad de distinguir los cambios en la VFC debidos a la incomodidad térmica de aquellos originados por el estrés laboral. Realizamos experimentos con sujetos utilizando el Test Avanzado de Trazado (ATMT) y observamos que el estrés altera la VFC, y que es posible distinguir sujetos estresados de no estresados con una precisión del 100%. Validamos nuestro método con el conjunto de datos de estrés de trabajo de conocimiento multimodal SWELL (SWELL-KW) y logramos resultados similares (99.25% de precisión y 99.75% de promedio de recuperación). Un análisis adicional sugiere que, aunque tanto el confort térmico como el estrés laboral afectan la VFC, sus efectos posiblemente no se superponen, y que ambos pueden distinguirse con una precisión casi perfecta. Estos resultados indican que podría ser posible diseñar un sistema automático y no intrusivo que proporcione confort térmico y prediga el estrés laboral basándose en la VFC de las personas (Nkurikiyeyezu et al., 2019).

1.10.4 SaYoPillow: Blockchain-Integrated Privacy-Assured IoMT Framework for Stress Management Considering Sleeping Habits

La toma de datos con sensores se realiza de manera continua mediante el dispositivo SaYoPillow. Este sistema integra varios sensores especializados diseñados para monitorear parámetros fisiológicos clave en tiempo real. Entre estos sensores se incluyen dispositivos para medir la frecuencia cardíaca, la temperatura corporal y los movimientos físicos. Por ejemplo, los sensores de frecuencia cardíaca registran variaciones en el ritmo cardíaco que pueden indicar respuestas al estrés. Los sensores de temperatura corporal detectan cambios sutiles que pueden correlacionarse con niveles de estrés. Los sensores de movimiento capturan datos sobre la actividad física, proporcionando información sobre patrones de actividad que pueden influir en el bienestar general del usuario. Estos datos son procesados localmente por un procesador de borde dentro del dispositivo para garantizar tiempos de respuesta rápidos y eficientes. Posteriormente, los resultados analizados se transfieren de manera segura a la nube de IoT para almacenamiento y análisis adicionales. Este enfoque

permite una monitorización precisa y continua de parámetros biológicos relevantes, facilitando así la implementación de estrategias personalizadas para el manejo del estrés y la mejora del bienestar del usuario (Rachakonda et al., 2016).

1.10.5 Depression Anxiety Stress Scales Responses

El conjunto de datos StressID se ha desarrollado con el propósito específico de facilitar la identificación del estrés mediante el análisis de datos unimodales y multimodales. Incluye registros de videos de expresiones faciales, grabaciones de audio y señales fisiológicas. Los videos y audios son capturados utilizando una cámara RGB con micrófono integrado, mientras que los datos fisiológicos consisten en señales de electrocardiografía (ECG), actividad electrodermal (EDA) y respiración, registrados mediante dispositivos wearable. Este diseño experimental asegura una recolección de datos multimodales de alta calidad y sincronización precisa.

El conjunto de datos incorpora diversos estímulos diseñados para inducir estrés, como clips de video emocionales, tareas cognitivas (como ejercicios matemáticos o de comprensión) y escenarios de hablar en público, con el objetivo de provocar respuestas emocionales variadas. En total, StressID contiene grabaciones de 65 participantes que completaron 11 tareas diferentes, junto con sus evaluaciones subjetivas de relajación percibida, estrés, nivel de activación y valencia emocional.

StressID se posiciona como uno de los conjuntos de datos más extensos para la identificación del estrés, al ofrecer datos anotados de más de 39 horas en total, provenientes de tres fuentes de datos distintas y una variedad de estímulos. Además de los datos brutos, el conjunto incluye modelos de referencia para la clasificación del estrés, que abarcan desde fases de limpieza y extracción de características hasta la fase de clasificación para cada modalidad por separado. Asimismo, se proporcionan modelos predictivos multimodales que integran entradas de video, audio y fisiológicas para mejorar la precisión en la identificación del estrés (Chaptoukaev et al., 2023).

1.11 Selección de dispositivos

Para la selección del equipo, se realizó un estudio exhaustivo de varios casos ya documentados. Estos casos demuestran que dichas variables son factores principales para la detección del estrés. Los estudios tienen validez internacional y han arrojado resultados de mediciones de estrés que son similares a los del campo en el que se desea aplicar.

Tabla 1

Selección de sensores

Variable	Sensor	Estudio
Temperatura	GikfunGikfun DS18B20 Temperature Sensor Waterproof Digital Thermal Probe Sensor for Arduino (Pack of 5pcs) EK1083	Stress-Lysis: A DNN- Integrated Edge Device for Stress Level Detection in the IoMT
Pulso	PULSE SENSOR (HEART-RATE MONITOR)	SaYoPillow: Blockchain- Integrated Privacy-Assured IoMT Framework for Stress Management Considering Sleeping Habits
Respiración	MQ-3 Detector	StressID: a Multimodal Dataset for Stress Identification

Fuente: Elaboración propia

CAPÍTULO 2

Desarrollo

El presente proyecto tiene como finalidad desarrollar una plataforma web con un modelo de inteligencia artificial que prediga el estrés mediante indicadores como la temperatura, la respiración y la frecuencia cardiaca. Además, se utilizará la versión en español de la Escala de Estrés Percibido (PSS) de 14 preguntas, con el fin de proporcionar una evaluación visual del estado de la persona tanto fisiológica como psicológicamente.

2.1 Visión general del proyecto

Se utilizó la metodología CRISP-DM junto con SCRUM para llevar a cabo el desarrollo y manejo de datos. El proceso comienza con la recolección de datos de bases de datos con estudios similares, con el objetivo de utilizar diferentes modelos de inteligencia artificial. SCRUM se utilizó para la realización de la página web, permitiendo trabajar por secciones y módulos, así como para el entrenamiento del modelo. CRISP-DM se empleó para la gestión de la base de datos, proporcionando una planificación estructurada que sirve como un proceso de desarrollo para el despliegue en producción y su posterior uso.

2.1.1 Planificación

La planificación del proyecto se estructuró en seis etapas clave, cada una alineada con la metodología SCRUM para asegurar una gestión eficiente y un desarrollo ágil. Se presenta una tabla detallada que resume las actividades principales y los resultados esperados de cada etapa, utilizando SCRUM como marco de trabajo.

Tabla 2.

Planificación del proyecto para su desarrollo

Etapa	Sprint	Actividades Principales	Resultados Esperados
1	1	Recolección de información para la base de datos	Selección de bases de datos óptimas para el tratamiento de datos
2	2-3	Selección y tratamiento de información utilizando CRISP-DM	Base de datos refinada para el entrenamiento
3	4-5	Creación y Entrenamiento del modelo de IA	Modelo de IA generado y entrenado

4	6-7	Desarrollo de hardware con sensores de pulso, respiración y temperatura	Hardware funcional con sensores integrados
5	8-9	Desarrollo Front end y Back end de la plataforma web	Plataforma web que acepta información fisiológica y la encuesta PSS-14
6	10-11	Recolección y análisis de datos	Análisis de los datos de los estudiantes con el uso de wilcoxon

Fuente: Elaboración propia

2.1.2 Entregables del proyecto

Entregables del proyecto titulación, junto con una descripción de cada uno.

Tabla 3.

Entregables del proyecto de titulación

Entregable	Descripción
Dataset de Entrenamiento	Conjunto de datos recopilados y tratados, utilizados para entrenar el modelo de inteligencia artificial. Incluye información de temperatura, respiración y frecuencia cardiaca, así como respuestas a la versión en español de la Escala de Estrés Percibido (PSS) de 14 preguntas.
Página Web	Plataforma web desarrollada para el ingreso de datos fisiológicos y las respuestas de la encuesta PSS-14. Permite la visualización de los resultados del análisis de estrés tanto fisiológico como psicológico.
Esquemas de Construcción del Dispositivo	Planos y esquemas detallados para la construcción del dispositivo de medición de estrés. El dispositivo incluye sensores de pulso, respiración y temperatura, y está diseñado para recolectar datos precisos y consistentes.
Modelo Entrenado (.pkl)	Archivo en formato .pkl que contiene el modelo de inteligencia artificial entrenado. Este modelo se utiliza para predecir el nivel de estrés basado en los datos fisiológicos y de la encuesta.


Fuente: Elaboración propia

2.2 Recopilación y análisis de datos

La primera etapa del proceso CRISP-DM se integra en la fase 1 del proyecto Scrum de desarrollo, correspondiente al Sprint 1. En esta etapa, recolectamos información crucial para identificar la base de datos relevante y generamos un modelo preliminar utilizando un gran volumen de datos. Posteriormente, este modelo será depurado y refinado para incluir únicamente los datos necesarios para nuestro análisis.

Figura 24

Sprint 1 Recolección de información




Fuente: Elaboración propia

Luego de ser asignada dentro del primer sprint para el desarrollo, se logró finalizar con el sprint 1. Como resultado, se completó la búsqueda de las bases de datos y los estudios del estrés que se utilizaron para seleccionar el conjunto de datos a emplear. Esta selección se realizó mediante la abstracción de información proveniente de sensores en diferentes partes del mundo.

Figura 25

Finalización de sprint 1 datos obtenidos tablero SCRUM



Fuente: Elaboración propia

Los resultados obtenidos se detallan en la tabla 4, con las bases de datos seleccionadas para el análisis de los parámetros de estrés.

Tabla 4

Bases de datos relevantes para la creación de data set de entrenamiento

Estudio	Data Set Encontrado	Parámetros
Introducing WESAD, a Multimodal Dataset for Wearable Stress and Affect Detection	HRV y EDA de los datasets SWELL1 y WESAD2	BVP (Volumen de Pulso Sanguíneo), ECG (Electrocardiograma), EDA (Actividad Electro dérmica), EMG (Electromiografía), RESP (Respiración), TEMP (Temperatura), ACC (Acelerómetro)
Stress-Lysis: A DNN-Integrated Edge Device for Stress Level Detection in the IoMT	Stress-Lysis	ECG (Electrocardiograma), frecuencia cardíaca, dispositivos portátiles (relojes, anillos, parches, insignias, gafas, pulseras)
SaYoPillow: Blockchain-Integrated Privacy-Assured IoMT Framework for Stress Management Considering Sleeping Habits	SaYoPillow	Número de horas de sueño, rango de ronquidos, rango de frecuencia respiratoria, rango de frecuencia cardíaca, rango de oxígeno en sangre, tasa de movimiento ocular o duración del tiempo en REM (Movimiento Rápido)

<p>The SWELL Knowledge hvr dataset Work Dataset for Stress and User Modeling Research</p>	<p>de los Ojos), tasa de movimiento de extremidades, cambio de temperatura corporal</p>
<p>StressID: a Multimodal StressID Dataset for Stress Identification</p>	<p>EEG (Electroencefalografía), EMG (Electromiografía), diámetro pupilar, ECG (Electrocardiograma), expresiones faciales, posturas, interacciones con la computadora ECG (Electrocardiograma), EDA (Actividad Electro dérmica), respiración, video facial, audio, autoevaluaciones (relajación, estrés, valencia, excitación)</p>

Fuente: Elaboración propia

Para el sprint 2, el objetivo fue seleccionar los datos más significativos relacionados con los niveles de estrés para el entrenamiento del modelo de IA usando CRISP-DM. Primero, se pasó por la comprensión del negocio, donde se reafirmaron los objetivos y requisitos del proyecto, enfocados en desarrollar un modelo de IA capaz de detectar y gestionar el estrés mediante el análisis de datos biométricos.


En segundo lugar, se comprendieron los datos. Se recopiló una base de datos general que incluía varias medidas biométricas: edad, frecuencia cardíaca, frecuencia respiratoria, temperatura corporal y nivel de estrés (representado en porcentaje). Estos datos provinieron de fuentes confiables reconocidas por su uso de biométricos en el ámbito comercial.

En tercer lugar, se prepararon los datos. Se realizó una limpieza inicial para eliminar valores atípicos y gestionar datos faltantes. Luego, se normalizaron las variables para asegurar la comparabilidad entre las diferentes medidas biométricas. Por último, se identificaron y seleccionaron los registros más relevantes utilizando la variable de estrés como referencia principal, asegurando la inclusión de datos significativos para el modelo.

El resultado del sprint 2 fue lograr una base de datos preliminar con registros significativos que servirán como base para el refinamiento y tratamiento en el siguiente sprint.

Figura 26

Sprint 2 finalizado con la base de datos sin refinar.



Fuente: Elaboración Propia.

En el sprint 3, se realizaron actividades enfocadas en la preparación avanzada y tratamiento de la información. Primero, se realizaron procesos adicionales de limpieza y normalización para mejorar la calidad de los datos. Se ajustaron y validaron los datos seleccionados en el Sprint 2, asegurando que solo los registros más relevantes y precisos fueran incluidos en la base de datos final.

Posteriormente, se procedió al modelado. Los datos refinados se segmentaron en conjuntos de entrenamiento y prueba. Se seleccionaron 7,000 datos significativos para el conjunto de entrenamiento y 3,000 para prueba, asegurando una representación equilibrada de diferentes niveles de estrés.


En la fase de evaluación, se llevaron a cabo pruebas preliminares del modelo de IA utilizando los datos refinados. Basado en los resultados de estas pruebas, se ajustaron los parámetros del modelo para mejorar su precisión y efectividad.

Finalmente, se implementó la base de datos de entrenamiento. Se preparó la base de datos para su integración en el modelo de IA, asegurando que los datos estuvieran en el formato adecuado y listos para ser utilizados en el proceso de aprendizaje automático. Se

verificó la calidad y formato de los datos, asegurando su compatibilidad con el entorno de desarrollo del modelo.

Figura 27

Finalización del sprint 3 con la base de datos lista para su uso en el modelo IA.



Fuente: Elaboración propia.

El resultado de este proceso es una base de datos robusta y confiable con 10,000 registros seleccionados cuidadosamente en función del nivel de estrés medido. En la Tabla 5, se muestra una vista de los primeros registros de la base de datos obtenida.

Tabla 5

Datos de entrenamiento del modelo.

Edad	Frecuencia Cardíaca	Frecuencia Respiratoria	Temperatura Corporal	Estrés (%)
26	105,4096442	24,56557919	37,19580928	80
23	76,5767031	14,83013818	37,04883127	29
30	76,83879796	14,22445708	36	20
27	105,0376419	22,24588441	36,86647188	59
24	70,37979643	12,65867211	37,14615368	12
26	60	13,11114137	36,18909585	0
29	99,39086135	24,37227145	37,57221334	64

22	84,00096676	18,5118526	36,54490657	32
26	78,13715716	21,17638888	36,00892519	37
30	69,00809898	17,61089436	37,25444241	24
30	73,27508492	17,06677366	36,59757062	25
27	108,8981677	23,23072855	37,99455426	76
24	87,95392877	24,75498222	37,02307839	58
23	111,1346061	30,91333621	37,80718609	91
27	80,56829943	17,10182902	36,44001508	32
27	125,4525938	28,38136047	38,10291752	100
22	85,45105372	20,70915946	36,5646464	40
25	79,27342392	13,57933178	36,14886242	29
24	98,6246086	22,87671274	37,02091861	56
21	96,78628905	23,63357844	37,22390952	48
27	95,62755943	19,69768456	37,52182963	47
25	92,39319202	25,26439699	36,74626641	71
21	89,29028956	20,84205964	37,40334594	48


Fuente: Elaboración propia.

2.3 Creación y entrenamiento del modelo de inteligencia artificial para la detección del estrés

En el marco del Sprint 4-5 del proyecto, se llevó a cabo la tarea de desarrollar y entrenar varios modelos de inteligencia artificial con el objetivo de identificar cuál de ellos proporcionaría el mejor rendimiento en la clasificación de datos. Este proceso implicó una serie de etapas meticulosamente planificadas y ejecutadas.

Figura 28

Sprint 4- 5 Realizados tablero SCRUM.



Fuente: Elaboración propia.

2.3.1 Variables del modelo de inteligencia artificial

En el desarrollo de modelos de inteligencia artificial para la monitorización de la salud, es fundamental la precisión en la adquisición de datos fisiológicos. Para este propósito, se emplean diversos sensores que capturan información crucial como la frecuencia cardíaca, la temperatura corporal y la frecuencia respiratoria. También se detalla cómo se utilizan estos sensores y se presentan los rangos normales de las variables medidas en personas adultas jóvenes.

2.3.1.1 Frecuencia Cardíaca con Pulse Sensor

El Pulse Sensor es un dispositivo compacto y eficiente diseñado para medir la frecuencia cardíaca de una persona. Este sensor funciona mediante la detección de cambios en el volumen sanguíneo que ocurren con cada latido del corazón. Estos cambios se detectan a través de una luz LED y un fotodiodo que capturan las variaciones en la luz reflejada, correlacionadas con el pulso sanguíneo.

2.3.1.2 *Temperatura Corporal con el Sensor Gikfun DS18B20*

El sensor de temperatura Gikfun DS18B20 es un sensor digital de alta precisión que se utiliza para medir la temperatura corporal. Este sensor ofrece una excelente precisión y puede ser fácilmente integrado en proyectos de electrónica. Funciona a través de un termómetro digital que convierte la temperatura en una señal digital, lo que facilita su lectura y procesamiento por parte de microcontroladores o sistemas de inteligencia artificial.

2.3.1.3 *Frecuencia Respiratoria con el Sensor MQ-3 Modificado*

El sensor MQ-3, originalmente diseñado para la detección de alcohol, ha sido modificado para detectar respiraciones humanas. Este sensor opera detectando cambios en la concentración de gases exhalados, como el dióxido de carbono, durante el proceso de respiración. A través de esta modificación, el sensor puede contar el número de respiraciones por minuto, proporcionando así una medida de la frecuencia respiratoria.

2.3.1.4 *Rangos Normales de Medidas Fisiológicas en Personas Adultas Jóvenes*

Los signos vitales son indicadores clave de las funciones esenciales del cuerpo, incluyendo el ritmo cardíaco, la frecuencia respiratoria, la temperatura y la presión arterial. Estos parámetros son monitoreados por los proveedores de atención médica para evaluar el estado físico general de una persona tabla 5. Los rangos normales de los signos vitales pueden variar en función de la edad, el sexo, el peso, la capacidad para ejercitarse y la salud general (medlineplus, 2023).

Para un adulto sano promedio en reposo, los rangos normales de los signos vitales son los siguientes:

- **Presión arterial:** entre 90/60 mmHg y 120/80 mmHg
- **Frecuencia respiratoria:** 12 a 18 respiraciones por minuto
- **Pulso:** 60 a 100 latidos por minuto
- **Temperatura corporal:** 97.8°F a 99.1°F (36.5°C a 37.3°C), con un promedio de 98.6°F (37°C)

Tabla 6

Rangos normales de los sensores

Variable	Rango de Edad	Rango Normal	Unidades
Fisiológica			
Frecuencia Cardíaca	18-25 años	60 - 100	Latidos por minuto (lpm)

Temperatura Corporal	18-25 años	36.1 - 37.2	Grados Celsius (°C)
Frecuencia Respiratoria	18-25 años	12 - 20	Respiraciones por minuto

Fuente: Elaboración propia.

2.3.2 Escala de medición del estrés

Para la medición de estrés, se generan dos secciones de interpretación, la interpretación de la Escala de Estrés Percibido (PSS-14) y el factor biométrico. Se recalca que ambos son instrumentos que permiten evidenciar cómo el cuerpo maneja el estrés tanto a nivel mental, con la Escala de Estrés Percibido, como a nivel físico, con los sensores biométricos. Estos dos enfoques combinados proporcionan una visión integral de cómo una persona está lidiando con el estrés.

2.3.2.1 Encuesta de estrés percibido

Para interpretar la Escala de Estrés Percibido (PSS-14) y clasificar los niveles de estrés, se utiliza la siguiente información de los puntos de corte consensuados en el texto proporcionado. La escala PSS-14 mide el grado en que las situaciones de vida son percibidas como estresantes, usando un formato de respuesta tipo Likert con 5 alternativas, de 0 (nunca) a 4 (muy a menudo). Las puntuaciones superiores indican un mayor estrés percibido. La puntuación total varía de 0 a 56.

2.3.2.1.1 Rango de Clasificación para la Escala de Estrés Percibido (PSS-14)

1. **0-14 puntos:** Casi nunca o nunca está estresado.
2. **15-28 puntos:** De vez en cuando está estresado.
3. **29-42 puntos:** A menudo está estresado.
4. **43-56 puntos:** Muy a menudo está estresado.

2.3.2.1.2 Cómo interpretar las puntuaciones:

- **Puntuaciones bajas (0-14):** Indican que la persona percibe pocas situaciones como estresantes y, en general, tiene bajos niveles de estrés.
- **Puntuaciones moderadas (15-28):** Reflejan que la persona percibe algunas situaciones como estresantes de vez en cuando. Esto sugiere un nivel moderado de estrés.
- **Puntuaciones altas (29-42):** Muestran que la persona percibe muchas situaciones como estresantes a menudo. Esto sugiere un alto nivel de estrés que podría requerir atención y manejo.

- **Puntuaciones muy altas (43-56):** Indican que la persona percibe la mayoría de las situaciones como estresantes muy a menudo, lo que sugiere niveles muy altos de estrés que probablemente necesiten intervención.

Este tipo de análisis es útil para identificar a las personas que podrían beneficiarse de técnicas de manejo del estrés o intervenciones para reducir el estrés (Torres-Lagunas et al., 2015).

2.3.2.2 Medición de factores de estrés con biométricos.

Para la medición del estrés se emplean dos secciones de interpretación: la Escala de Estrés Percibido (PSS-14) y los factores biométricos. Estos instrumentos permiten evidenciar cómo el cuerpo maneja el estrés tanto a nivel mental, mediante la escala PSS-14, como a nivel físico, mediante sensores biométricos. A continuación, se detallan los métodos y rangos utilizados para evaluar el estrés con biométricos, específicamente el pulso, la frecuencia respiratoria y la temperatura corporal.

2.3.2.2.1 Métodos

Para evaluar el nivel de estrés mediante biométricos, se establece una escala de estrés de 0 a 100, donde 0 indica ausencia de estrés y 100 indica un nivel muy alto de estrés. Los factores biométricos considerados son:

1. Frecuencia Cardíaca (Pulso)
2. Frecuencia Respiratoria
3. Temperatura Corporal

2.3.2.2.2 Rangos de Frecuencia Cardíaca

- Bajo Estrés (0-25): 60-80 latidos por minuto (lpm)
- Moderado Estrés (26-50): 81-100 lpm
- Alto Estrés (51-75): 101-120 lpm
- Muy Alto Estrés (76-100): Más de 120 lpm

2.3.2.2.3 Rangos de Frecuencia Respiratoria

- Bajo Estrés (0-25): 12-20 respiraciones por minuto
- Moderado Estrés (26-50): 21-25 respiraciones por minuto
- Alto Estrés (51-75): 26-30 respiraciones por minuto
- Muy Alto Estrés (76-100): Más de 30 respiraciones por minuto

2.3.2.2.4 Rangos de Temperatura Corporal

- Bajo Estrés (0-25): 36.5-37°C
- Moderado Estrés (26-50): 37.1-37.5°C

- Alto Estrés (51-75): 37.6-38°C
- Muy Alto Estrés (76-100): Más de 38°C

2.3.2.2.5 Interpretación Combinada de los Factores Biométricos

Para obtener una interpretación combinada de los factores biométricos en la escala de estrés de 0 a 100, se utiliza un enfoque ponderado. A continuación, se describe el proceso:

1. **Asignación de puntos individuales:** Se asignan puntos a cada biométrico de acuerdo con los rangos establecidos.
2. **Cálculo de la media:** Se calcula la media de los puntos asignados para obtener un valor final de estrés en la escala de 0 a 100.

2.3.2.2.6 Ejemplo de Cálculo

Supongamos que se tienen las siguientes medidas para una persona:

- Frecuencia Cardíaca: 95 lpm
- Frecuencia Respiratoria: 23 respiraciones por minuto
- Temperatura Corporal: 37.3°C

Puntuación según rangos:

- Frecuencia Cardíaca: Moderado Estrés (45 puntos)
- Frecuencia Respiratoria: Moderado Estrés (40 puntos)
- Temperatura Corporal: Moderado Estrés (40 puntos)

Media ponderada: $Estrés\ Total = \frac{45+40+40}{3} = 41.67$

Este valor indica un nivel de estrés moderado, aproximadamente 42 en una escala de 0 a 100 (Andrés Valencia Zambrano, 2018).

2.3.3 Selección y preparación de modelos

Para abordar la creación del modelo de inteligencia artificial, se seleccionaron tres algoritmos ampliamente reconocidos por su eficacia y robustez en tareas de clasificación: el Support Vector Machine (SVM), el Random Forest y el Extreme Gradient Boosting (XGBoost). Estos modelos fueron escogidos debido a sus características distintivas y su capacidad para manejar datos complejos de manera eficiente.

2.3.4 Normalización de los datos

Para comparar los niveles de estrés predichos por el modelo de IA y los obtenidos mediante la Prueba de Estrés Percibido (PSS14), se realizó una normalización de los datos ajustando todos los valores del modelo de IA a una escala en la que 56 puntos representan el 100%. Este proceso es esencial para asegurar una comparación equitativa y directa entre ambos conjuntos de datos, ya que la escala de la PSS14 ya se maneja en 56 puntos.

2.3.4.1 Fórmula de Normalización

Dado que 56 es el 100%, la fórmula utilizada para normalizar los datos del modelo de IA es:

$$\text{Valor Normalizado} = \frac{x \times 100}{56}$$

Donde:

x es el valor original del dato.

2.3.4.2 Realización de la Normalización

Aplicando la fórmula a los datos de estrés predichos por la IA:

2.3.4.3 Estrés Predicho por IA:

Ejemplo: Para un valor de estrés predicho de 37:

$$\text{Valor en Puntos de Estrés} = \frac{66.07 \times 56}{100} \approx 37$$

2.3.4.4 Estrés Percibido:

Los valores de la PSS14 ya están en la escala de 56 puntos, por lo que no requieren normalización adicional.

2.3.4.5 Explicación de la Normalización

La normalización convierte los valores de estrés predichos por la IA a puntos de estrés dentro de la misma escala utilizada por la PSS14. Por ejemplo, un valor de estrés predicho de 66.07% se normaliza a aproximadamente 37 puntos, lo que permite comparar directamente los niveles de estrés entre ambos métodos en la misma escala. Esto asegura que las diferencias se interpreten correctamente en el contexto de la escala completa.

Esta normalización es crucial para garantizar que las comparaciones entre los niveles de estrés predichos por el modelo de IA y los obtenidos por la PSS14 sean justas y precisas, reforzando así la validez del modelo de IA en la evaluación del estrés.

2.3.5 Selección del modelo para su uso en la web

Después de realizar diversos entrenamientos y ajustes de hiperparámetros, se determinó que el modelo Random Forest proporcionó los mejores resultados. Este rendimiento superior se debe a la capacidad del modelo para manejar eficientemente la variabilidad y complejidad de los datos de entrenamiento.

El Random Forest, al construir múltiples árboles de decisión y combinar sus resultados, mejora la precisión y robustez de las predicciones. La evaluación del modelo, basada en métricas como el error cuadrático medio (MSE), el coeficiente de determinación

(R^2), el error absoluto medio (MAE) y el error absoluto mediano (MedAE), demostró que Random Forest supera a otros modelos probados.

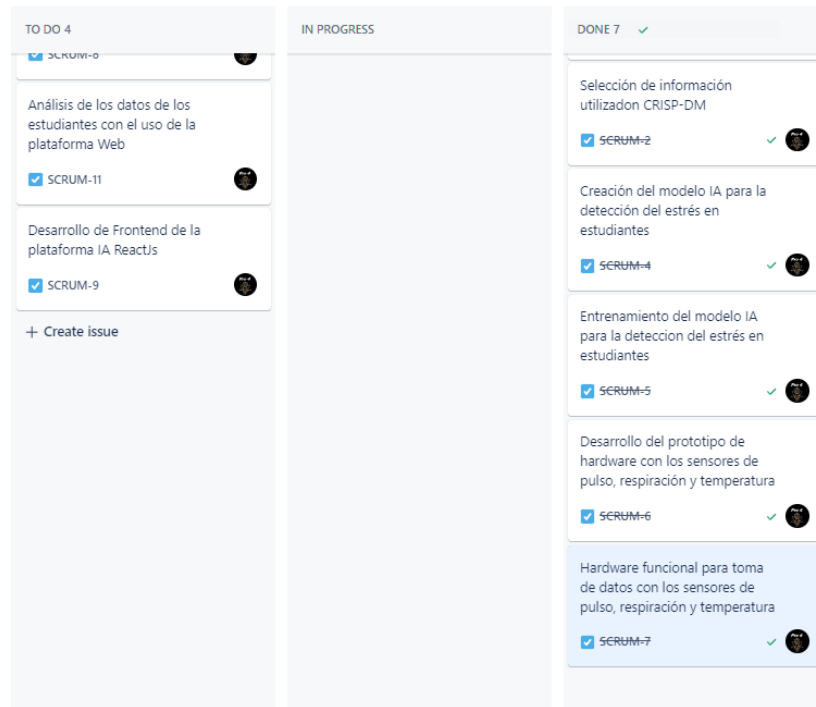
En particular, el modelo Random Forest se destacó por su capacidad para minimizar los errores de predicción y mantener un alto valor de R^2 , lo que indica una excelente capacidad para explicar la variabilidad en los datos de estrés. Además, su desempeño consistente tanto en los conjuntos de entrenamiento como en los de prueba subraya la robustez del modelo, haciendo de Random Forest la mejor elección para este conjunto de datos específicos.

2.4 Creación de hardware para la recopilación de datos

En el dispositivo, que forma parte del sprint 6 -7 figura 40 de Desarrollo del prototipo de hardware con los sensores de pulso, respiración y temperatura, se realizaron varios análisis con el objetivo de integrar todos los sensores dentro de un solo dispositivo. Estos análisis fueron llevados a cabo utilizando el software Fusion 360, en el cual se diseñaron las partes internas del dispositivo, asegurando que todos los sensores cupieran adecuadamente. Se detallaron las partes internas, permitiendo la correcta disposición de los sensores. La interacción del dispositivo con la interfaz se realiza mediante botones, los cuales se programan utilizando Arduino IDE en código C++ con su variante específica. Dentro del dispositivo, se diseñaron menús detallados que pueden ser visualizados en una pantalla LCD I2C, lo que permite observar los resultados de los diferentes sensores.

Figura 29

Sprint 6-7 Realizados tablero SCRUM.



Fuente: Elaboración propia.

2.4.1 Diseño en Fusion 360


Fusion 360 es un software de diseño asistido por computadora (CAD) desarrollado por Autodesk. Este software permite a los ingenieros y diseñadores crear modelos 3D detallados y precisos, realizar simulaciones y análisis de ingeniería, así como preparar archivos para la impresión 3D. Fusion 360 es especialmente valorado por su capacidad para integrar todo el proceso de diseño en una sola plataforma, desde la conceptualización hasta la fabricación (Autodesk, 2024).

2.4.1.1 Tapa Frontal

En la parte frontal figura 41 del dispositivo se encuentra una pantalla LCD de cristal líquido que muestra los menús y los resultados de los sensores. Además, en la parte superior frontal se ha colocado un indicador LED que permite revisar los estados de los sensores. En la parte inferior de la parte frontal se encuentra una botonera que permite la interacción con el software del dispositivo.

Figura 30

Parte frontal dispositivo de control de estrés.




Fuente: Elaboración propia.

2.4.1.2 Tapa superior

La tapa superior figura 42 incluye una ranura específica para cargar el código en el microcontrolador ESP32 interno. Esta ranura está diseñada para proteger el dispositivo de suciedad y otros elementos externos. También contiene dos tornillos que aseguran la tapa frontal al resto del dispositivo.

Figura 31

Parte superior dispositivo de control de estrés.



Fuente: Elaboración propia.


2.4.1.3 Tapa Izquierda

En la tapa izquierda figura 43 se encuentra el botón de encendido del dispositivo. También están ubicadas varias ranuras para sensores, incluyendo:

- MQ3, para un sensor de frecuencia respiratoria, con una entrada de 3 pines.
- Pulso, para un sensor que mide los latidos por minuto, con una entrada de 3 pines.
- Temperatura, para un sensor de temperatura corporal, con una entrada de 3 pines.
- EMG, una ranura adicional reservada para una futura actualización con un sensor EMG (electromiografía), adaptada para su entrada específica.

Figura 32

Parte izquierda dispositivo de control de estrés.



Fuente: Elaboración propia.

2.4.1.4 Tapa inferior y Tapa Derecha

La parte inferior figura 44 del dispositivo incluye la zona de carga, permitiendo conectar una fuente de alimentación para recargar la batería. También se encuentran los tornillos de anclaje inferior que aseguran la cara frontal del dispositivo.

Figura 33

Parte inferior dispositivo de control de estrés.



Fuente: Elaboración propia

2.4.1.5 Tapa Derecha y Tapa Trasera

Las tapas derecha figura 45 y trasera figura 46 del dispositivo son parte de la estructura y protección del equipo. Aunque no contienen componentes electrónicos ni sensores, su diseño es fundamental para asegurar la integridad y el cierre adecuado del dispositivo.

Figura 34

Parte derecha dispositivo de control de estrés.



Fuente: Elaboración propia.

Figura 35

Parte trasera dispositivo de control de estrés.



Fuente: Elaboración propia.

2.4.2 Creación de circuito interno.

Para la creación del circuito interno, se utilizó el software Proteus. Proteus es una herramienta de diseño de placas de circuito impreso (PCB) que permite simular y verificar el funcionamiento de los circuitos antes de su fabricación. En este caso, la placa diseñada contiene todas las conexiones necesarias, y la fabricación de esta se realiza mediante el método de planchado, lo que permite transferir el diseño del circuito a una placa de cobre (Proteus, 2024).

2.4.2.1 Entradas de los Sensores

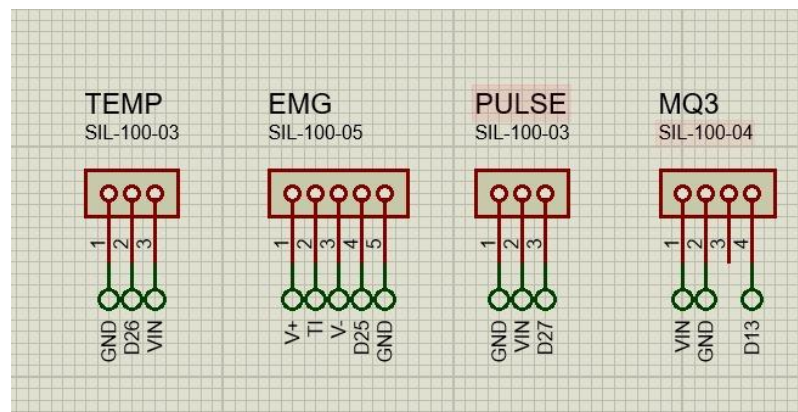
Para la integración de los sensores figura 47, se realizaron las siguientes conexiones detalladas:

1. Sensor de Temperatura:
 - Pin 1: Neutro
 - Pin 2: Señal del sensor
 - Pin 3: Alimentación (3V)
2. Sensor EMG (Electromiografía):
 - Pin 1: Voltaje positivo
 - Pin 2: Tierra de la fuente simétrica

- Pin 3: Voltaje negativo
 - Pin 4: Señal
 - Pin 5: Neutro o tierra
3. Sensor de Pulso:
- Pin 1: Tierra
 - Pin 2: Alimentación
 - Pin 3: Señal
4. Sensor MQ3 (Frecuencia Respiratoria):
- Pin 1: Energía
 - Pin 2: Neutro
 - Pin 3: Señal

Figura 36

Conexiones de sensores.



Fuente: Elaboración propia.

2.4.2.2 Iluminación y visualización de datos

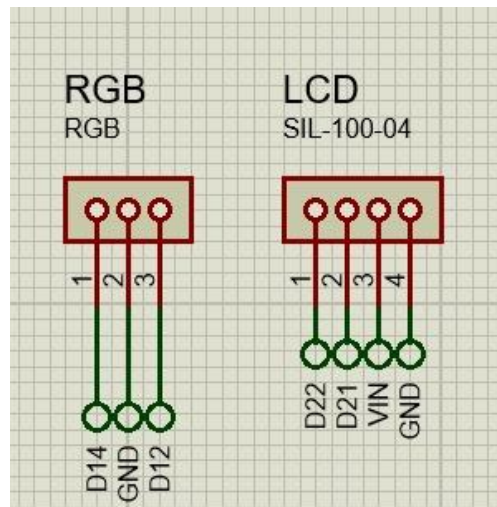
Para la visualización de datos y la iluminación figura 48, se realizaron las siguientes conexiones:

1. RGB LED:
 - Pin 1: Señal
 - Pin 2: Neutro
 - Pin 3: Señal que alimenta el RGB
2. Pantalla LCD:
 - Pin 1: Señal I2C
 - Pin 2: Señal I2C
 - Pin 3: Alimentación

- Pin 4: Neutro

Figura 37

Conexiones RGB y Pantalla LSD I2C.



Fuente: Elaboración propia.


2.4.2.3 Batería

Para la alimentación del dispositivo figura 49, se realizaron las siguientes conexiones en la batería:

- Pin 1: Alimentación
- Pin 2: Neutro

Figura 38

Conexiones batería interna.



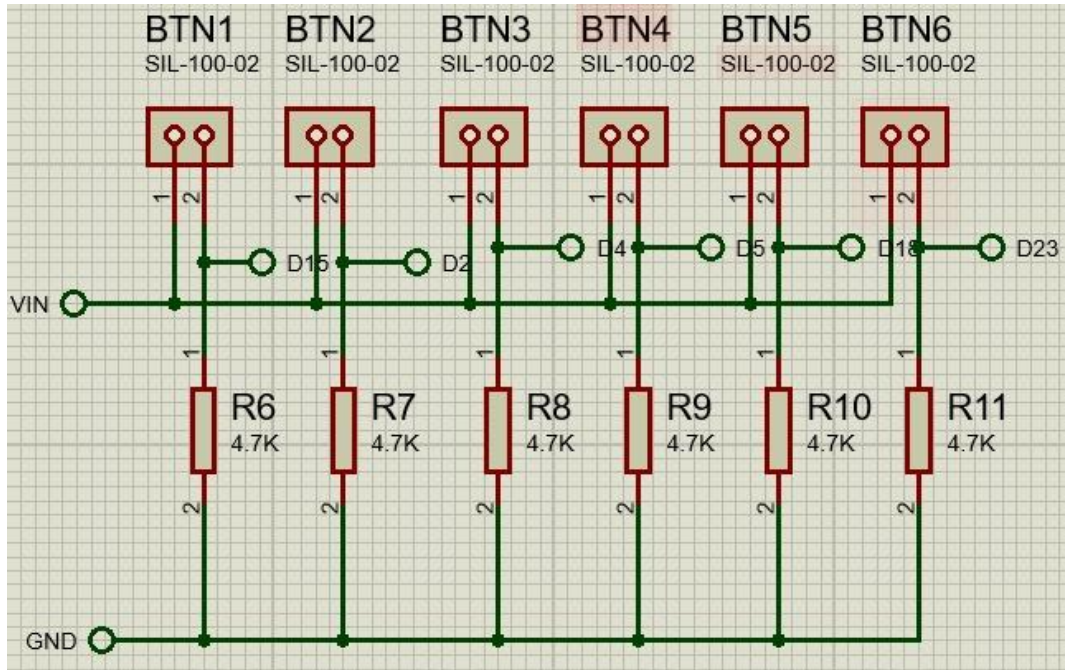
Fuente: Elaboración propia.

2.4.2.4 Botonera

La botonera se configuró con conexiones tipo pull-up y resistencias para suavizar la señal emitida figura 50. Esta configuración es crucial para asegurar el manejo adecuado de la interfaz de usuario.

Figura 39

Conexión de la botonera en configuración pull-up.




Fuente: Elaboración propia.

2.4.2.5 Inversor de Batería

El diseño del inversor de batería es fundamental para el sensor EMG figura 50. Este inversor se implementa en los planos para visualizar las salidas de voltajes simétricos de +5V y -5V, necesarios para el correcto funcionamiento del sensor.

Figura 40

Circuito inversor de +5V y -5V



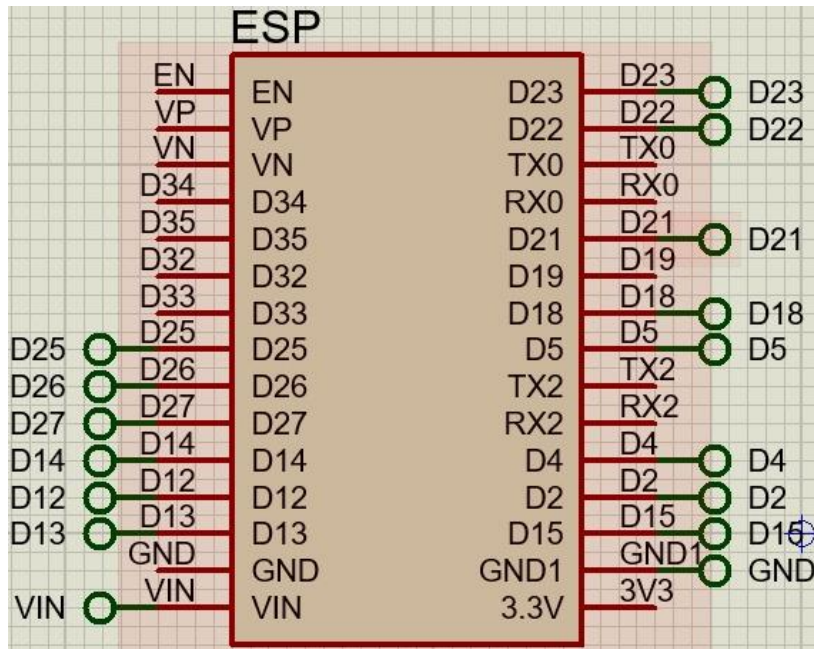
Fuente: Elaboración propia.

2.4.2.6 *Microcontrolador ESP32*

La ESP32 se conecta a los sensores previamente detallados figura 52. Los sensores están colocados en los canales disponibles y de fácil accesibilidad dentro del microcontrolador, garantizando la mejor construcción de la placa para sus conexiones.

Figura 41

Conexiones en la ESP32




Fuente: Elaboración propia.

2.4.2.7 *Diseño de placa*

El diseño de la placa figura 53 incluye todas las pistas y conexiones necesarias, visualizadas en Proteus. Estas pistas se transferirán manualmente a una placa de cobre mediante el método de planchado, asegurando una construcción precisa del circuito.

Figura 42

Placa de conexiones de los sensores con la ESP32




Fuente: Elaboración propia.

2.4.2.8 Diseños en 3D de los Componentes

Los modelos en 3D de los componentes fueron generados en Proteus para visualizar la placa con todos los componentes ensamblados. En la vista superior figura 54, se puede observar la distribución de los componentes y su ubicación en la placa. Además, el modelo 3D permite visualizar las rutas figura 55 de toda la electrónica, mostrando claramente cómo serán las pistas y su disposición final en el dispositivo.

Figura 43


Placa 3D de componentes internos.



Fuente: Elaboración propia.

Figura 44

Rutas de cobre de la placa principal.



Fuente: Elaboración propia.

2.4.3 Codificación del dispositivo en Arduino IDE.

El código desarrollado en el entorno de Arduino IDE está diseñado para medir y visualizar parámetros fisiológicos como el pulso, la temperatura y la respiración. A continuación, se describe detalladamente el funcionamiento del código, clasificando cada parte para una mejor comprensión.

2.4.3.1 Bibliotecas y Configuración Inicial

En la primera sección del código, se incluyen las bibliotecas necesarias para manejar los diferentes componentes del sistema:

- Wire.h: Proporciona la funcionalidad para la comunicación I2C.
- LiquidCrystal_I2C.h: Maneja la pantalla LCD a través de la comunicación I2C.
- PulseSensorPlayground.h: Controla el sensor de pulso, permitiendo la lectura y procesamiento de los datos de pulso.
- OneWire.h y DallasTemperature.h: Se utilizan para manejar los sensores de temperatura basados en el protocolo OneWire.

Se define la dirección I2C y el tamaño de la pantalla LCD, y se configura el sensor de temperatura utilizando el bus OneWire. Además, se establecen las constantes y pines necesarios para el sensor de respiración y los pulsadores.

2.4.3.2 Configuración en la Función setup()

En la función setup(), se realizan varias inicializaciones críticas:

- Inicialización de Sensores y Pantalla: Los sensores de temperatura y pulso, así como la pantalla LCD, se inicializan. Esto incluye establecer la comunicación con los sensores y preparar la pantalla LCD para mostrar información.
- Mensaje de Bienvenida: Se muestra un mensaje de bienvenida en la pantalla LCD para informar al usuario que el sistema está listo.
- Configuración de Pulsadores: Los pines a los que están conectados los pulsadores se configuran como entradas, permitiendo al sistema detectar las interacciones del usuario.
- Llamada a MenuHome(): La función MenuHome() se llama para mostrar el menú principal en la pantalla LCD, permitiendo al usuario seleccionar entre las opciones de medición.

2.4.3.3 Bucle Principal (loop())

La función loop() es el corazón del código y contiene la lógica principal para medir y mostrar los datos de los sensores:

- **Lectura del Pulso:** Si el flag correspondiente está activado, se mide el pulso utilizando el sensor. La frecuencia cardíaca en latidos por minuto (BPM) se calcula y se muestra en la pantalla LCD. El usuario puede salir de esta pantalla y volver al menú principal pulsando un botón específico.
- **Lectura de la Temperatura:** Similar a la lectura del pulso, si el flag correspondiente está activado, se mide la temperatura corporal utilizando el sensor de temperatura. La temperatura se muestra en la pantalla LCD y el usuario puede salir de esta pantalla pulsando un botón.
- **Lectura de la Respiración:** Este proceso es más complejo e incluye un tiempo de estabilización del sensor. Durante este tiempo, el sistema espera a que el sensor MQ3 se estabilice antes de comenzar las lecturas. La frecuencia respiratoria se mide contando los pulsos detectados y se muestra en la pantalla LCD. Como en los otros casos, el usuario puede salir de esta pantalla pulsando un botón.

2.4.3.4 Gestión del Menú

La función MenuHome() muestra el menú principal en la pantalla LCD, permitiendo al usuario seleccionar entre las opciones de medición de pulso, temperatura y respiración. Dependiendo del botón que el usuario presione, se llama a la función correspondiente para la medición seleccionada:

- FR(): Función que maneja la selección y el inicio de la medición de la frecuencia respiratoria.
- TEP(): Función que maneja la selección y el inicio de la medición de la temperatura.
- PULSE(): Función que maneja la selección y el inicio de la medición del pulso.

Cada una de estas funciones muestra un submenú con opciones para iniciar la medición o volver al menú principal.

2.4.3.5 Funciones de Inicio de Medición

Las funciones INICIOFR (), INICIOPULSO() y INICIOTEP() se encargan de preparar el sistema para la medición específica seleccionada. Estas funciones:

- **Reinician Variables:** Aseguran que todas las variables necesarias para la medición estén en su estado inicial.
- **Preparan la Interfaz de Usuario:** Actualizan la pantalla LCD con mensajes e instrucciones pertinentes para el usuario.
- **Activan los Flags Correspondientes:** Establecen los flags correspondientes a true, lo que permite que el bucle principal loop() procese las lecturas de los sensores.

2.4.3.6 Flujograma de funcionamiento del programa

El funcionamiento del programa comienza con la inicialización de todas las variables necesarias. A continuación, se muestra un mensaje de inicio en la pantalla LCD del hardware, indicando "Control de Estrés por Isaac Romero". Después de este mensaje, el programa presenta el menú principal (MenuHome), donde se pueden seleccionar diferentes opciones de medición:

- Frecuencia Respiratoria
- Temperatura
- Pulso

Estas opciones permiten navegar entre los distintos menús. A continuación, se describen las funcionalidades de cada opción:

2.4.3.6.1 Frecuencia Respiratoria

Al seleccionar la opción de Frecuencia Respiratoria, el usuario tiene dos opciones: "Iniciar" o "Salir". Si se elige "Salir", el sistema retorna al menú principal. Si se selecciona "Iniciar", el dispositivo comienza a tomar y procesar los datos de la frecuencia respiratoria.

2.4.3.6.2 Temperatura

Al ingresar en el menú de Temperatura, nuevamente se presentan dos opciones: "Iniciar" o "Salir". Si se elige "Salir", el sistema vuelve al menú principal. Si se selecciona "Iniciar", el dispositivo comienza la medición de la temperatura corporal.

2.4.3.6.3 Pulso


En el menú de Pulso, se muestran las opciones "Iniciar" o "Salir". Si se selecciona "Salir", el sistema retorna al menú principal. Si se selecciona "Iniciar", el dispositivo mide y muestra la frecuencia cardíaca en latidos por minuto (LPM) del usuario.

Para apagar el dispositivo, se utiliza un interruptor (switch) que, al ser accionado, corta el suministro de energía, apagando el dispositivo por completo.

El flujo de funcionamiento del programa se detalla en la Figura 56, donde se presenta el diagrama de flujo del código, ilustrando las transiciones entre los diferentes estados y opciones del menú.

Figura. 45

Flujograma del programa del dispositivo de control de estrés



Fuente: Elaboración propia.

2.5 Creación de plataforma de recolección de datos


Para la detección del estrés, se desarrolló una plataforma de recolección de datos utilizando Django para el backend y ReactJS para el frontend. La base de datos fue gestionada mediante PostgreSQL, y los servicios se desplegaron en Railway para la API de Django, Render para la base de datos y Firebase para el frontend. Esta arquitectura permitió la creación de una página web que facilitó la recolección y manejo de datos de los estudiantes, asegurando la integridad y accesibilidad de la información recopilada.

2.5.1 Desarrollo de Backend de la plataforma IA django

El backend se desarrolló utilizando Django, organizándolo de manera que permitiera una gestión eficiente de las rutas mediante Django Rest Framework. Este framework se utilizó para gestionar las rutas que manejan la información relacionada con encuestas, sensores y usuarios, tal como se planificó en el sprint 8 figura 57, donde se detallaron estos requerimientos específicos.

Figura. 46

Sprint 8 Realizados tablero SCRUM



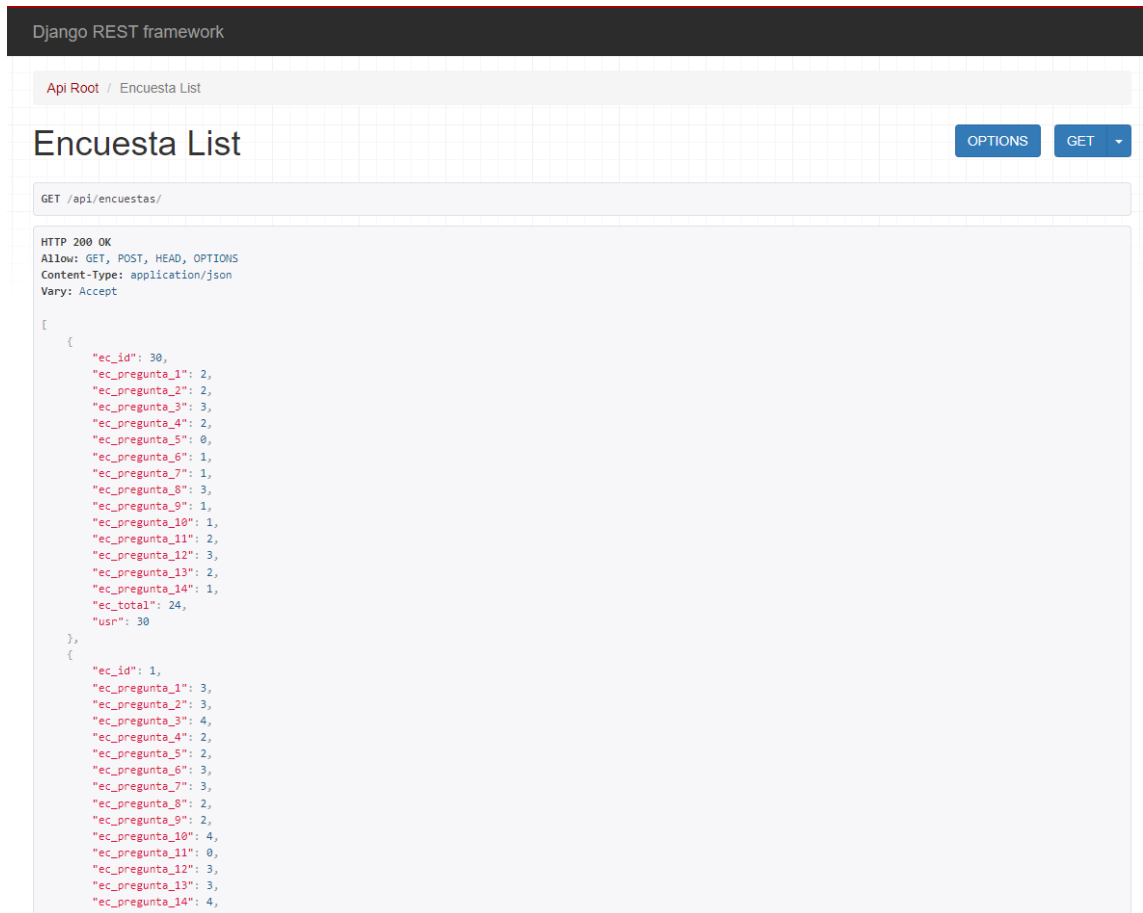
Fuente: Elaboración propia

2.5.1.1 Rutas de encuestas estrés percibido:

Se creó una ruta dedicada para manejar las encuestas figura 58. En esta ruta, se almacenan los diferentes valores de las encuestas, que contienen 14 preguntas con respuestas en un rango de 0 a 4. Los datos de la encuesta se almacenan y, mediante un trigger interno, se realiza automáticamente la suma de todos los ítems. Esta tabla se asocia con el número de usuario interno, facilitando el seguimiento y análisis individualizado.

Figura 47

Ruta encuesta de estrés percibido



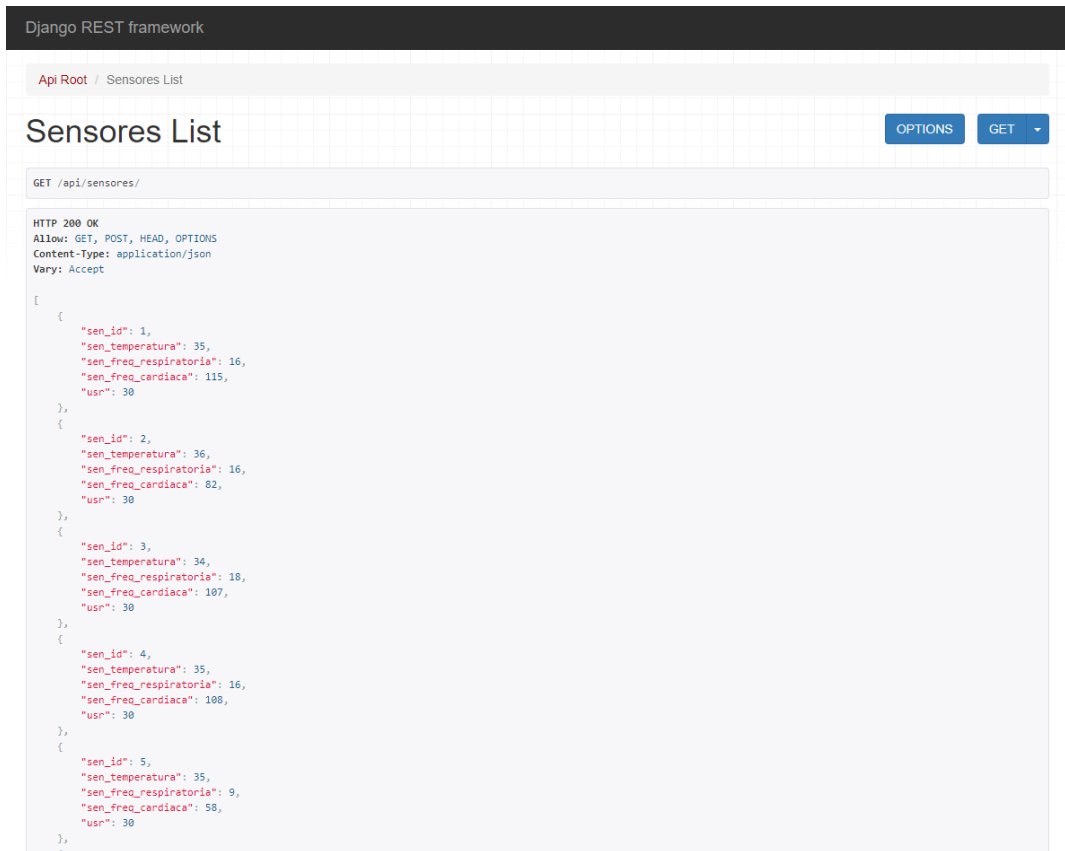
Fuente: Elaboración propia.

2.5.1.2 Rutas de sensores biométricos:

Se implementó una ruta para almacenar los valores recogidos por los sensores figura 59, incluyendo temperatura, frecuencia cardíaca y número de usuario. Estos datos son cruciales para el análisis y se comparan con un modelo entrenado para obtener resultados precisos.

Figura 48

Ruta sensores biométricos.



```
Django REST framework
Api Root / Sensores List
Sensores List
OPTIONS GET
GET /api/sensores/
HTTP 200 OK
Allow: GET, POST, HEAD, OPTIONS
Content-Type: application/json
Vary: Accept
[
  {
    "sen_id": 1,
    "sen_temperatura": 35,
    "sen_freq_respiratoria": 16,
    "sen_freq_cardiaca": 115,
    "usr": 30
  },
  {
    "sen_id": 2,
    "sen_temperatura": 36,
    "sen_freq_respiratoria": 16,
    "sen_freq_cardiaca": 82,
    "usr": 30
  },
  {
    "sen_id": 3,
    "sen_temperatura": 34,
    "sen_freq_respiratoria": 18,
    "sen_freq_cardiaca": 107,
    "usr": 30
  },
  {
    "sen_id": 4,
    "sen_temperatura": 35,
    "sen_freq_respiratoria": 16,
    "sen_freq_cardiaca": 108,
    "usr": 30
  },
  {
    "sen_id": 5,
    "sen_temperatura": 35,
    "sen_freq_respiratoria": 9,
    "sen_freq_cardiaca": 58,
    "usr": 30
  }
]
```

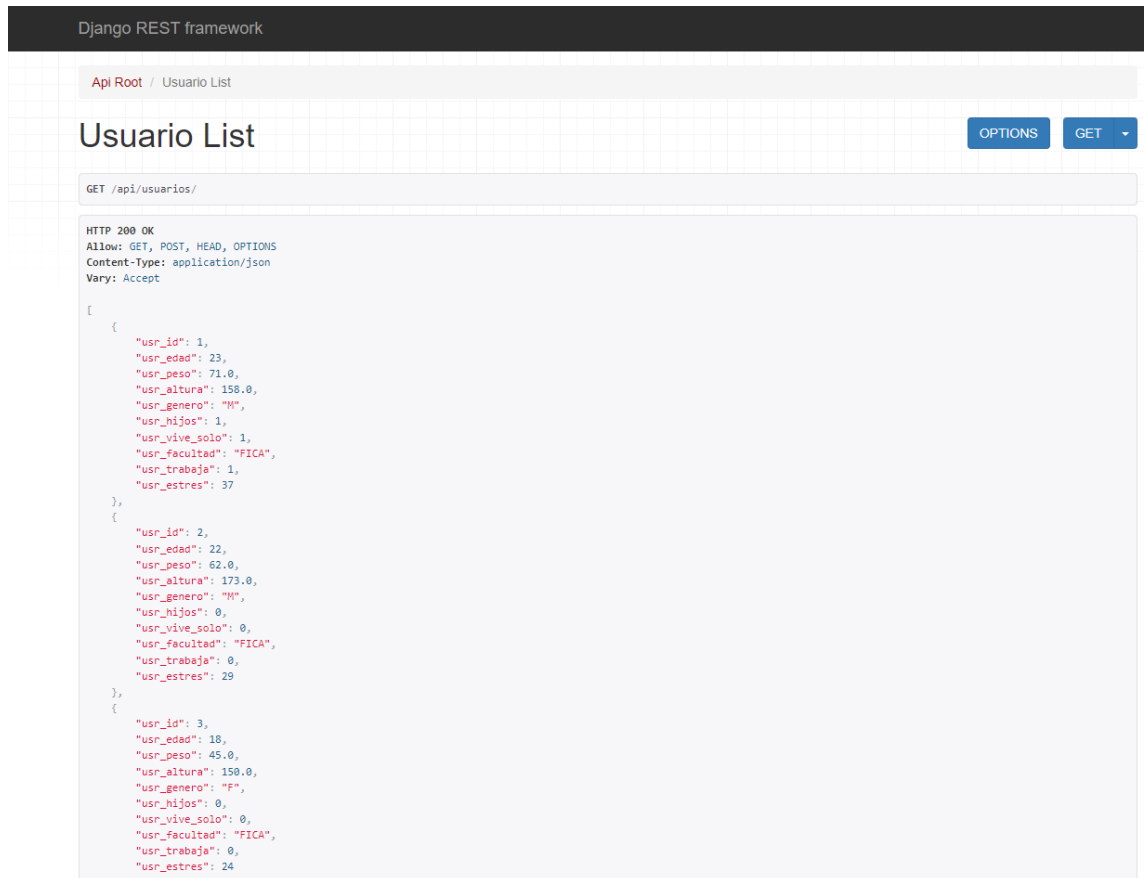
Fuente: Elaboración propia.

2.5.1.3 *Rutas de Usuarios:*

En la ruta de usuarios figura 60, se guarda información detallada del usuario, como edad, peso, altura, género, si tiene hijos, si vive solo, a qué facultad pertenece y si trabaja. Además, se almacena el porcentaje de estrés calculado por el modelo entrenado. Esta información es esencial para personalizar el análisis y proporcionar estadísticas específicas para cada individuo.

Figura 49

Ruta de usuario



Elaboración propia

2.5.1.4 Modelo Entrenado:

El modelo entrenado se integra dentro del backend utilizando archivos de modelo y escalador (modelo_entrenado.pkl y scaler.pkl). Estos archivos se cargan y se utilizan para predecir el nivel de estrés de los estudiantes basándose en los datos recogidos por los sensores y otra información relevante.


El proceso comienza con la carga del modelo y el escalador mediante el uso de la biblioteca joblib. Para realizar una predicción, se extraen las características relevantes de los sensores, que incluyen la temperatura, la frecuencia respiratoria y la frecuencia cardíaca. Además, se considera la edad del usuario como una característica adicional. Estas características se normalizan utilizando el escalador previamente cargado.

Una vez normalizadas las características, se verifica que el número de características proporcionadas coincida con el número esperado por el modelo. Si hay una discrepancia en el número de características, se genera un error para asegurar la coherencia en el procesamiento de datos.

Finalmente, el modelo utiliza las características normalizadas para hacer una predicción del nivel de estrés del usuario. Este valor predicho se guarda automáticamente en la base de datos asociada al usuario, permitiendo un análisis continuo y actualizado del estrés en los estudiantes. Este proceso automatizado y la integración del modelo en el backend facilitan la implementación y aseguran que los datos se procesen de manera eficiente y precisa.

Figura 50

Integración del modelo de detección de estrés dentro de la API



Fuente: Elaboración propia.

2.5.2 Elaboración de frontend de la página detección de estrés.

El desarrollo de la plataforma de detección del estrés se realizó utilizando ReactJS, conforme a lo establecido en el sprint 9. La web se desarrolló siguiendo los lineamientos del manual de marca institucional de la Universidad Técnica del Norte, detallados en el documento "MANUAL DE MARCA UTN 18102022". Este manual establece que todas las comunicaciones oficiales deben alinearse gráficamente para ser fácilmente reconocibles. Además, orienta y simplifica la tarea de quienes generan piezas informativas o publicitarias para la institución. El documento muestra diferentes variables de uso de la marca y su aplicación en piezas gráficas, asegurando uniformidad. El cumplimiento de estas directrices proporciona beneficios como un posicionamiento sólido y un fortalecimiento de la confianza pública. Es fundamental seguir las recomendaciones para mantener la línea gráfica y


consolidar la imagen institucional. Cualquier producto comunicacional debe ser aprobado por la Unidad de Relaciones Públicas antes de su difusión, y su colocación debe seguir las normas establecidas (Universidad Técnica del Norte, 2024).

2.5.2.1 Módulos del Sitio Web

La página de control de Estrés describe los módulos principales del sitio web desarrollado para la recolección de datos y detección del estrés, estos módulos son creados para poder manejar de mejor forma los contenidos internos conforme se estableció en el sprint 9 figura 62, para poder facilitar el manejo del modelo IA.

Figura 51

Sprint 9 Realizados tablero SCRUM



Fuente: Elaboración propia.

2.5.2.1.1 Inicio

En la sección de Inicio figura 63, se proporciona una descripción del dispositivo de estrés, detallando su funcionamiento y la manera en que se tratarán los datos recopilados. Esta sección sirve como una introducción para los usuarios, explicando los objetivos y el propósito del dispositivo.

Figura 52

Inicio página de control de estrés.




Fuente: Elaboración propia.

2.5.2.1.2 Estudiante

La pantalla de Estudiante permite ingresar los datos personales del estudiante acorde al sprint 10 figura 64, tales como edad, peso, altura, género, si tiene hijos, si vive solo, la facultad a la que pertenece, si trabaja y el nivel de estrés calculado por el modelo, en puntos EEP14, En porcentaje de estrés y estado del nivel del estres. Esta sección también permite modificar o eliminar los datos del estudiante según sea necesario como se muestra en la figura 65.

Figura. 53

Sprint 10 Realizados tablero SCRUM



Fuente: Elaboración propia.

Figura. 54

Ingreso de estudiantes página de control de estrés.

ID	Edad	Peso	Altura	Género	Hijos	Vive Solo	Facultad	Trabaja	Estrés EEP14	Reporte Estrés	Estrés en %	Acciones
1	23	71	158	M	1	1	FICA	1	37	alto nivel de estrés	de 66	
2	22	62	173	M	0	0	FICA	0	29	alto nivel de estrés	de 51	
3	18	45	150	F	0	0	FICA	0	24	nivel moderado de estrés	de 42	
4	24	100	173	M	1	0	FICA	1	29	alto nivel de estrés	de 51	
5	20	76	158	F	0	0	FECYT	0	27	nivel moderado de estrés	de 48	
6	23	70	168	M	0	1	FICA	0	39	alto nivel de estrés	de 69	
7	23	72	184	M	0	0	FICA	0	29	alto nivel de estrés	de 51	

Fuente: Elaboración propia.

2.5.2.1.3 Pantalla de la Encuesta EEP (Escala de Estrés Percibido)

La sección de Encuesta EEP presenta un cuestionario con 14 preguntas recolectado información acorde al sprint 10, donde el estudiante selecciona la respuesta que mejor describe su situación. Una vez completada la encuesta, los resultados se envían para su procesamiento figura 66, contribuyendo al análisis global del estrés del estudiante.

Figura. 55

Encuesta de estrés percibido página control de estrés.

Pregunta 1 de 14

1. En el último mes, ¿con qué frecuencia ha estado afectado por algo que ha ocurrido inesperadamente?

Nunca

Casi Nunca

De vez en cuando

A menudo

Muy a menudo

Regresar Siguiente

Desarrollado por Isaac Romero - 2024

Fuente: Elaboración propia.

2.5.2.1.4 Signos Vitales

En la sección de Signos Vitales figura 67, se guardan los resultados de las mediciones del usuario, incluyendo temperatura, frecuencia respiratoria y frecuencia cardíaca. Los datos se asocian automáticamente con el número de usuario mediante un trigger interno. Esta sección permite editar o eliminar registros y añadir nuevas mediciones a través de un modal, estas para que puedan ser usadas por el modelo IA integrado esto se guarda acorde el sprint 10 figura 64.

Figura. 56

Ingreso de los valores de los sensores para la página de control estrés.

ID	Temperatura	Frecuencia Respiratoria	Frecuencia Cardíaca	Usuario	Acciones
1	35	16	115	1	[Editar] [Eliminar]
2	36	16	82	2	[Editar] [Eliminar]
3	34	18	107	3	[Editar] [Eliminar]
4	35	16	108	4	[Editar] [Eliminar]
5	35	9	58	5	[Editar] [Eliminar]
6	36	7	94	6	[Editar] [Eliminar]
7	37	9	90	7	[Editar] [Eliminar]

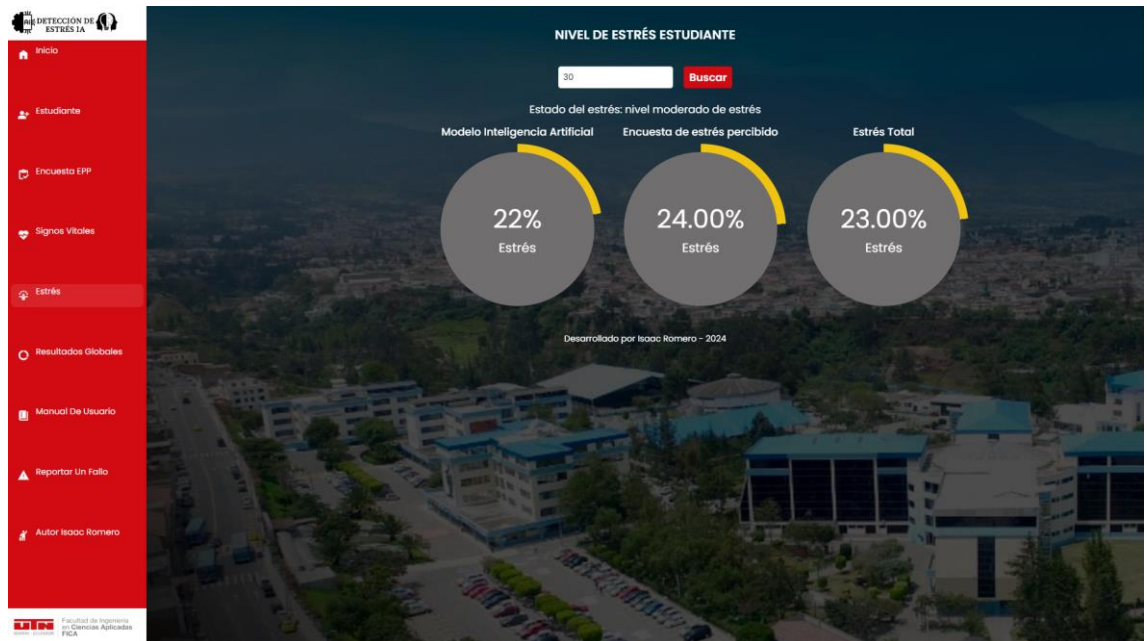
Fuente: Elaboración propia.

2.5.2.1.5 Estrés

La sección de Estrés muestra los niveles de estrés de cada estudiante, calculados tanto por el modelo de IA como por los resultados de la encuesta EEP. Se proporciona un resumen total del estrés del estudiante figura 68, ofreciendo una visión clara y detallada de su estado.

Figura. 57

Niveles de estrés dentro de la plataforma control de estrés.




Fuente: Elaboración propia.

2.5.2.1.6 Resultados Globales

En Resultados Globales figura 69, se presenta una visión agregada de los datos de los estudiantes, desglosada por facultad. Aunque se tomó una muestra de 30 estudiantes para este análisis, la sección muestra gráficos de pastel que representan el número de estudiantes con y sin estrés, proporcionando una visión general de los datos recopilados.

Figura. 58

Resultados globales control de estrés.




Fuente: Elaboración propia.

2.5.2.1.7 Manual de Usuario

La sección de Manual de Usuario ofrece instrucciones detalladas sobre el uso del dispositivo y la página web figura 70. Aquí se describe cada componente de la plataforma y se proporcionan guías para asegurar un uso adecuado y efectivo.

Figura. 59

Manual de usuario página control estres.



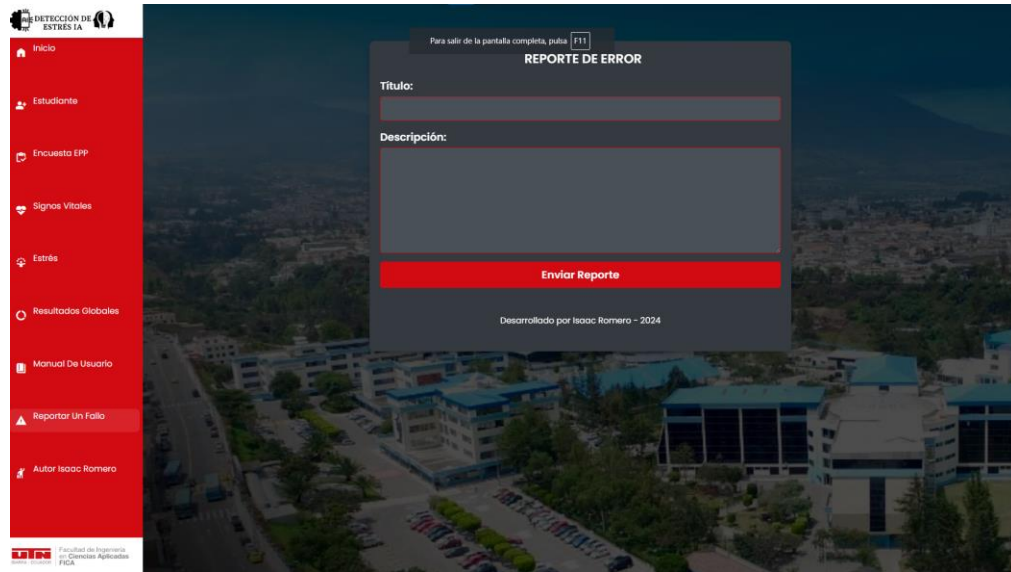
Fuente: Elaboración propia.

2.5.2.1.8 Reportar un Error

En Reportar un Error figura 71, los usuarios pueden enviar reportes sobre cualquier problema encontrado en la página web. Esto facilita la comunicación con los desarrolladores y ayuda a mantener la funcionalidad de la página, asegurando que los errores se corrijan de manera oportuna.

Figura. 60

Reportar el error de la página control de estrés.




Fuente: Elaboración propia.

2.5.2.1.9 Autor

La sección de Autor proporciona una explicación sobre la motivación del autor para desarrollar esta página figura 72. Aquí se ofrece un resumen de los objetivos del proyecto y se busca inspirar a otros, explicando el propósito y la importancia de la detección del estrés en estudiantes.

Figura. 61

Detalles del autor de la página control de estrés.



Fuente: Elaboración propia.

CAPITULO 3

Validación de resultados

Para la validación de los resultados, se utilizaron métricas del modelo Random Forest. Estas métricas se utilizan para evaluar el desempeño del modelo en la regresión, específicamente en el cálculo del porcentaje de estrés en los estudiantes. La segunda validación viene por parte de un profesional médico, quien verifica que el modelo funciona correctamente y que las variables obtenidas son adecuadas para el manejo del estrés. La tercera validación fue llevada a cabo por la toma de datos a estudiantes, sus resultados fueron ingresados dentro del modelo con sus percepciones personales de estrés tomadas por la prueba EEP14(*Estrés percibido*), permitiendo así evaluar la correlación entre el modelo y las pruebas de estrés percibido mediante el uso de wilcoxon.

3.1 Métricas Generales de los modelos

Para seleccionar el modelo más adecuado para su posterior integración en la plataforma web, se realizó una evaluación exhaustiva de varios algoritmos de aprendizaje automático. A continuación, se presentan los resultados generales obtenidos de los modelos probados, los cuales permitieron identificar el más eficiente en términos de precisión y desempeño para la detección temprana de estrés en los estudiantes.

3.1.1.1 *Resultados del Modelo SVM*

La evaluación del modelo se realizó utilizando varias métricas, como el error cuadrático medio (MSE), el coeficiente de determinación (R^2), el error absoluto medio (MAE) y el error absoluto mediano (MedAE). Los resultados obtenidos se presentan en la Figura 29, donde se comparan las métricas en los conjuntos de entrenamiento y prueba.

3.1.1.2 *Las métricas obtenidas son las siguientes:*

Train MSE: 26.968

Test MSE: 38.178

Train R^2 : 0.968

Test R^2 : 0.955

Train MAE: 4.068

Test MAE: 4.916


Train MedAE: 3.347

Test MedAE: 3.996

Estos resultados indican que el modelo tiene un desempeño consistente en ambos conjuntos, de entrenamiento y prueba, con errores relativamente bajos y un alto valor de R^2 , lo que sugiere que el modelo explica bien la variabilidad de los datos.

Figura 62

Resultados del entrenamiento de SVM



Fuente: Elaboración propia.


3.1.1.3 Valores Reales vs Predicciones SVM:

La Figura 30 muestra una comparación entre los valores reales y las predicciones del modelo. Se observa una fuerte correlación entre los valores reales y las predicciones, con los puntos de datos agrupándose alrededor de la línea ideal.

Esto sugiere que el modelo SVM es capaz de predecir con precisión los niveles de estrés basados en las variables fisiológicas proporcionadas. La alineación de los puntos a lo largo de la línea diagonal indica que las predicciones están cerca de los valores reales, demostrando la efectividad del modelo.

Figura 63

Valores reales vs predicciones modelo SVM.



Fuente: Elaboración propia.

3.1.1.4 Histograma del Error de Predicción SVM:


El histograma del error de predicción, mostrado en la figura 31, ilustra la distribución de los errores de predicción. La mayoría de los errores se concentran alrededor de 0, formando una distribución aproximadamente normal.

Esto indica que el modelo no presenta grandes sesgos y los errores de predicción son generalmente pequeños. La simetría del histograma alrededor de 0 sugiere que los errores positivos y negativos están equilibrados, lo que refuerza la robustez y precisión del modelo SVM en la predicción de niveles de estrés.

Estos gráficos y métricas demuestran que el modelo SVM ha sido eficaz en la predicción de niveles de estrés, con un buen ajuste y una distribución equilibrada de errores, lo que respalda su aplicación en problemas similares de regresión.

Figura 64

Histograma del error de predicción.



Fuente: Elaboración propia.

3.1.1.5 Resultados del Modelo XGBoost

La evaluación del modelo se realizó utilizando varias métricas, como el error cuadrático medio (MSE), el coeficiente de determinación (R^2), el error absoluto medio (MAE) y el error absoluto mediano (MedAE). Los resultados obtenidos se presentan en la Figura 33, donde se comparan las métricas en los conjuntos de entrenamiento y prueba.

Las métricas obtenidas son las siguientes:

Train MSE: 36.088

Test MSE: 37.446

Train R^2 : 0.957

Test R^2 : 0.955

Train MAE: 4.794

Test MAE: 4.876


Train MedAE: 4.070

Test MedAE: 4.066

Estos resultados indican que el modelo tiene un desempeño consistente en ambos conjuntos, de entrenamiento y prueba, con errores relativamente bajos y un alto valor de R^2 , lo que sugiere que el modelo explica bien la variabilidad de los datos.

Figura 65

Resultados del entrenamiento de XGBoost.



Fuente: Elaboración propia.


3.1.1.6 Valores Reales vs Predicciones XGBoost

La Figura 34 muestra una comparación entre los valores reales y las predicciones del modelo. Se observa una fuerte correlación entre los valores reales y las predicciones, con los puntos de datos agrupándose alrededor de la línea ideal.

Esto sugiere que el modelo XGBoost es capaz de predecir con precisión los niveles de estrés basados en las variables fisiológicas proporcionadas. La alineación de los puntos a lo largo de la línea diagonal indica que las predicciones están cerca de los valores reales, demostrando la efectividad del modelo.

Figura 66

Valores reales vs predicciones XGBoost



Fuente: Elaboración propia

3.1.1.7 Histograma del Error de Predicción XGBoost


El histograma del error de predicción, mostrado en la Figura 35, ilustra la distribución de los errores de predicción. La mayoría de los errores se concentran alrededor de 0, formando una distribución aproximadamente normal.

Esto indica que el modelo no presenta grandes sesgos y los errores de predicción son generalmente pequeños. La simetría del histograma alrededor de 0 sugiere que los errores positivos y negativos están equilibrados, lo que refuerza la robustez y precisión del modelo XGBoost en la predicción de niveles de estrés.

Estos gráficos y métricas demuestran que el modelo XGBoost ha sido eficaz en la predicción de niveles de estrés, con un buen ajuste y una distribución equilibrada de errores, lo que respalda su aplicación en problemas similares de regresión.

Figura 67

Histograma del error predicción.



Fuente: Elaboración propia.

3.1.1.8 Resultados del modelo Random Forest

La evaluación del modelo Random Forest se realizó utilizando varias métricas, como el error cuadrático medio (MSE), el coeficiente de determinación (R^2), el error absoluto medio (MAE) y el error absoluto mediano (MedAE). Los resultados obtenidos se presentan en la Figura 37, donde se comparan las métricas en los conjuntos de entrenamiento y prueba.

Las métricas obtenidas son las siguientes:

Train MSE: 37.009

Test MSE: 37.006

Train R^2 : 0.956

Test R^2 : 0.956

Train MAE: 4.816

Test MAE: 4.817

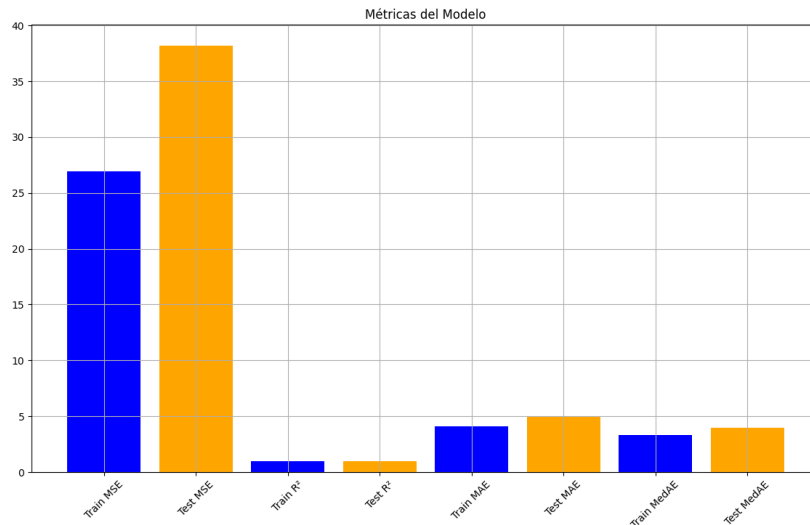
Train MedAE: 4.029

Test MedAE: 3.959

Estos resultados indican que el modelo tiene un desempeño consistente en ambos conjuntos, de entrenamiento y prueba, con errores relativamente bajos y un alto valor de R^2 , lo que sugiere que el modelo explica bien la variabilidad de los datos.

Figura 68

Métricas del modelo Random Forest



Fuente: Elaboración propia.


3.1.1.9 Valores reales vs predicciones Random Forest

La Figura 38 muestra una comparación entre los valores reales y las predicciones del modelo. Se observa una fuerte correlación entre los valores reales y las predicciones, con los puntos de datos agrupándose alrededor de la línea ideal.

Esto sugiere que el modelo Random Forest es capaz de predecir con precisión los niveles de estrés basados en las variables fisiológicas proporcionadas. La alineación de los puntos a lo largo de la línea diagonal indica que las predicciones están cerca de los valores reales, demostrando la efectividad del modelo.

Figura 69

Valores reales vs predicciones modelo Random Forest.



Fuente: Elaboración propia.

3.1.1.10 Histograma del Error de Predicción Random Forest


El histograma del error de predicción, mostrado en la Figura 39, ilustra la distribución de los errores de predicción. La mayoría de los errores se concentran alrededor de 0, formando una distribución aproximadamente normal.

Esto indica que el modelo no presenta grandes sesgos y los errores de predicción son generalmente pequeños. La simetría del histograma alrededor de 0 sugiere que los errores positivos y negativos están equilibrados, lo que refuerza la robustez y precisión del modelo Random Forest en la predicción de niveles de estrés.

Estos gráficos y métricas demuestran que el modelo Random Forest ha sido eficaz en la predicción de niveles de estrés, con un buen ajuste y una distribución equilibrada de errores, lo que respalda su aplicación en problemas similares de regresión.

Figura 70

Histograma del error de predicción Random Forest.



Fuente: Elaboración propia.

3.2 Métricas detalladas del modelo seleccionado Random Forest

Las métricas desempeñan un papel crucial en el análisis de resultados, ya que permiten evaluar la eficacia y precisión de un modelo predictivo. En el contexto de la regresión utilizando el modelo Random Forest, estas métricas son fundamentales para comprender cómo se está comportando el modelo en términos de su capacidad para predecir con precisión los valores esperados.

3.2.1 Valores reales vs predicciones

la relación entre los valores reales del estrés en estudiantes (en el eje X) y las predicciones generadas por el modelo (en el eje Y) figura 73. Cada punto en el gráfico representa un par de valor real-predicción.

3.2.1.1 Interpretación:

En la figura 73, se observa que la relación entre los valores reales y las predicciones abarca un rango completo desde 0 hasta 100%. Esto sugiere que el modelo ha sido capaz de capturar la variabilidad total en los datos de estrés, prediciendo valores en todo el espectro de la variable dependiente. La línea ideal, representada en negro, indica una predicción perfecta. La mayoría de los puntos azules se alinean cerca de esta línea, lo que sugiere una fuerte correlación entre los valores predichos y los reales. Específicamente, podemos ver que para valores reales alrededor de 50% de estrés, las predicciones se concentran en un rango cercano de 48% a 52%, lo cual indica una precisión bastante alta en esa región del conjunto de datos. La dispersión es mayor en los extremos (cercanos a 0% y 100%), lo que es común en modelos de regresión debido a la menor cantidad de datos en estos rangos.

3.2.1.2 Fórmula Matemática:

La fórmula que representa esta relación es:

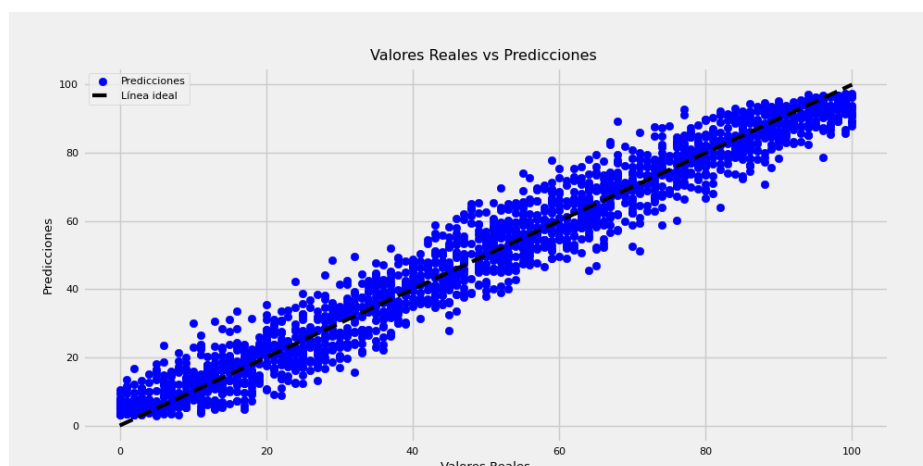
$$\hat{y} = f(X)$$

Donde:

- \hat{y} es el valor predicho por el modelo.
- $f(x)$ es la función del modelo que toma las variables independientes (Edad, Frecuencia Cardíaca, Frecuencia Respiratoria, Temperatura Corporal) para predecir el estrés.

Figura 71

Valores Reales vs Predicciones.



Fuente: Elaboración propia.

3.2.2 *Histograma de error de predicción*

Este histograma muestra la distribución de los errores de predicción figura 74, que es la diferencia entre los valores reales y las predicciones generadas por el modelo.

3.2.2.1 *Interpretación:*

Este histograma figura 74 muestra que el error de predicción, es decir, la diferencia entre los valores predichos y los reales está centrado en 0, lo que sugiere que no existe un sesgo sistemático en las predicciones del modelo. La mayoría de los errores se encuentran en el rango de -5% a 5%, con un pico alrededor de 0%, lo que indica que la mayoría de las predicciones están a menos de 5 puntos porcentuales del valor real. Por ejemplo, hay más de 200 instancias donde el error es aproximadamente de -2%, lo que indica una ligera subestimación en estas predicciones. La presencia de algunos errores extremos, tanto positivos como negativos (superiores a 10% o inferiores a -10%), sugiere que, aunque el modelo es en general preciso, todavía existen casos en los que las predicciones podrían mejorarse, posiblemente ajustando más el modelo o utilizando más datos de entrenamiento.

3.2.2.2 *Fórmula Matemática:*

El error de predicción (e) se calcula como:


$$e = y - y^{\wedge}$$

Donde

- y es el valor real
- y^{\wedge} es el valor predicho

Figura 72

Histograma del error de prección



Fuente: Elaboración propia.

3.2.3 Evolución del Out-of-Bag Error vs. Número de Árboles

Este método muestra cómo evoluciona el out-of-bag error a medida que se incrementa el número de árboles en el modelo Random Forest figura 75.

3.2.3.1 Interpretación:

En la figura 75 ilustra cómo el out-of-bag error (OOB error) cambia a medida que se incrementa el número de árboles en el modelo Random Forest. Inicialmente, con un pequeño número de árboles (por ejemplo, menos de 20), el OOB error es alto, alrededor de -1.5 en términos de R^2 , lo que indica un modelo subajustado. A medida que se añaden más árboles, el OOB error mejora rápidamente, alcanzando un R^2 cercano a 1.0 cuando se utilizan alrededor de 50 árboles. Más allá de este punto, el rendimiento se estabiliza, y agregar más árboles no mejora significativamente el OOB error. Esto sugiere que un modelo con aproximadamente 50 a 100 árboles es óptimo, alcanzando un R^2 de 0.98 en el entrenamiento, lo cual indica una excelente capacidad predictiva del modelo con este número de árboles.

3.2.3.2 Fórmula Matemática:

La estimación del error de predicción se puede expresar como:


$$OOB_error = \frac{1}{N} \sum_{i=1}^N (y_i - y_i^{OOB})^2$$

Donde:

- N es el número total de observaciones.
- y_i es el valor real
- y_i^{OOB} es la predicción del modelo únicamente árboles que no incluyeron la observación i en su conjunto de entrenamiento.

Figura 73

Evolución del out-of-bag-error vs números árboles.



Fuente: Elaboración propia.

3.2.4 Evolución del CV Error vs. Número de Árboles

En esta comparación se muestra cómo evoluciona el error de validación cruzada (cross-validation error) a medida que se incrementa el número de árboles en el modelo figura 76.

3.2.4.1 Interpretación:

En la figura 76 muestra la evolución del error de validación cruzada (CV error) a medida que se incrementa el número de árboles. Similar al OOB error, el CV error disminuye rápidamente cuando se agregan árboles, estabilizándose alrededor de 100 árboles. Con un número reducido de árboles, el CV error comienza cerca de 9, lo que indica un modelo con bajo poder predictivo. Sin embargo, al aumentar el número de árboles a alrededor de 50, el CV error disminuye a aproximadamente 6, lo que implica una mejora significativa en la precisión del modelo. La curva se aplana después de los 50 árboles, lo que sugiere que agregar más árboles no proporciona beneficios adicionales, y se puede considerar este punto como óptimo para el modelo.

3.2.4.2 Fórmula Matemática

El error de validación cruzada se calcula como:


$$CV_error = \frac{1}{k} \sum_{i=1}^k (y_i - y_i^{CV})^2$$

Donde:

- k es el número de pliegues en la validación cruzada.
- y_i^{CV} es la predicción del modelo para el pliegue i .

Figura 74

Evolución del cv-error vs número párbolos



Fuente: Elaboración propia.

3.2.5 Importancia de los Predictores

La importancia de cada predictor (variable independiente) en el modelo, basado en la técnica de permutación figura 77.

3.2.5.1 Interpretación:

En la figura 77 destaca la importancia relativa de cada predictor en el modelo de regresión, evaluado mediante la técnica de permutación. Se observa que la Frecuencia Cardíaca tiene la mayor importancia, con un incremento del error de aproximadamente 20 puntos porcentuales cuando se permuta, lo que indica su fuerte impacto en la predicción del estrés. La Frecuencia Respiratoria sigue en importancia, con un incremento del error cercano a 10 puntos porcentuales. La Temperatura Corporal tiene una influencia menor, con un impacto de aproximadamente 7.5 puntos porcentuales en el error cuando se permuta. Finalmente, la Edad tiene la menor importancia relativa, con un incremento del error de solo 2 puntos porcentuales. Esto sugiere que, aunque la Edad tiene cierta influencia en el modelo, es significativamente menor en comparación con las otras variables fisiológicas.

3.2.5.2 Fórmula Matemática

La importancia del predictor se mide por la pérdida en precisión ($\Delta Accuracy$) al permutar la variable:

$$\Delta Accuracy = Accuracy_{original} - Accuracy_{permutada}$$


Donde:

- $Accuracy_{original}$ es la precisión del modelo con los datos originales.

- $Accuracy_{permutada}$ es la precisión tras permutar la variable.

Figura 75

Importancia de los predictores.



Fuente: Elaboración propia.

3.2.6 Métricas del modelo

En estos resultados se compara diferentes métricas del modelo entre los conjuntos de entrenamiento y prueba figura 78.

3.2.6.1 Interpretación:

En la figura 78 compara varias métricas de evaluación del modelo, destacando las diferencias entre el conjunto de entrenamiento y el de prueba. Se observa que el MSE (Mean Squared Error) es significativamente mayor en el conjunto de prueba (37.96) en comparación con el conjunto de entrenamiento (23.80), lo que indica que el modelo tiene un rendimiento ligeramente inferior cuando se enfrenta a nuevos datos, aunque sigue siendo bastante preciso. El R^2 es elevado tanto en el conjunto de entrenamiento (0.97) como en el de prueba (0.95), lo que indica que el modelo explica la mayoría de la variabilidad de los datos en ambos casos. Las métricas MAE (Mean Absolute Error) y MedAE (Median Absolute Error) también son cercanas entre el conjunto de entrenamiento y prueba, lo que sugiere una buena generalización del modelo. Estos resultados en conjunto indican que el modelo es robusto, aunque existe una ligera disminución de rendimiento en el conjunto de prueba, lo cual es normal y esperado en la mayoría de los modelos predictivos.

3.2.6.2 Fórmulas Matemáticas:

- MSE: $MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$
- R^2 : $R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$
- MAE: $MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$
- MedAE: $MedAe = mediana(|y_i - \hat{y}_i|)$

Donde:

Tabla 7

Explicativas de las siglas utilizadas

Sigla	Descripción
MSE	Mean Squared Error - Error Cuadrático Medio
R ²	Coefficiente de Determinación
MAE	Mean Absolute Error - Error Absoluto Medio
MedAE	Median Absolute Error - Error Absoluto Mediano

Fuente: Elaboración propia.

Figura 76

Resultados del entrenamiento.

```
Train MSE: 23.80189291442988, Train R2: 0.971809226494271  
Test MSE: 37.964348284036674, Test R2: 0.9548363918152658  
Train MAE: 3.9067821232289526, Test MAE: 4.904934614064954  
Train MedAE: 3.331804792283336, Test MedAE: 4.039227457708712
```

3.3 Validación médica del dispositivo y modelo de estrés.

El dispositivo desarrollado para la medición de niveles de estrés ha sido evaluado y validado tanto por medios técnicos como por un médico local, asegurando su eficacia y seguridad en la toma de datos biométricos.

3.3.1.1 Eficacia en la Detección del Estrés

- **Medición del Pulso:** Utiliza un sensor preciso que registra la frecuencia cardíaca, proporcionando datos en tiempo real sobre el ritmo cardíaco, un indicador crucial de la respuesta al estrés.
- **Medición de la Temperatura Corporal:** El sensor de temperatura monitorea la temperatura corporal para detectar una reacción fisiológica al estrés.
- **Medición de la Respiración:** A través de la evaluación de la frecuencia, el dispositivo ofrece una visión de la respuesta del sistema respiratorio al estrés.

3.3.1.2 Validez y Confiabilidad del Dispositivo

- **Uso de la escala de estrés percibido:** La web emplea la Escala de Estrés Percibido, una herramienta reconocida internacionalmente para la evaluación del estrés

percibido. Esta escala ha sido validada por el Departamento de Psicología Biológica y de la Salud de la Facultad de Psicología de la Universidad Autónoma de Madrid, lo que garantiza la precisión y confiabilidad de los datos obtenidos y asegura que la web cumple con los más altos estándares internacionales.

- **Método de Toma de Datos:** La metodología de toma de datos fue diseñada para realizarse de forma expresa, evitando la necesidad de registros prolongados. Esto es crucial para minimizar la fatiga del usuario y asegurar la captura precisa de las respuestas fisiológicas inmediatas al estrés.

3.3.1.3 Aspectos Éticos en la Medición del Estrés

- **Protección de Datos Personales:** La web cumple con protección de datos, asegurando que la información biométrica recopilada sea manejada con la máxima confidencialidad y seguridad.
- **Consentimiento Informado:** Se garantiza que los usuarios sean informados adecuadamente sobre el uso del dispositivo y los datos que serán recopilados, asegurando un consentimiento plenamente informado.

3.3.1.4 Cumplimiento de Normativas y Estándares Médicos

- **Manejo de normativas y estándares:** Además de la validación por la PSS14, el dispositivo ha sido diseñado para cumplir con las normativas internacionales aplicables, lo que lo habilita para su uso en contextos clínicos y académicos de manera segura y efectiva validado por un médico local anexo1.

3.3.2 Prueba de Normalidad

Para evaluar la normalidad de los datos obtenidos, se aplicó la prueba de Shapiro-Wilk a las variables "Estrés Predicho por IA" y "Estrés Percibido". Los resultados fueron los siguientes:

- Estrés Predicho por IA: $W = 0.9808, p = 0.8463$
- Estrés Percibido: $W = 0.9490, p = 0.1590$

Dado que ambos valores p son mayores que 0.05, no se rechaza la hipótesis nula de normalidad, lo que sugiere que ambas variables siguen una distribución normal. Esto valida el uso de pruebas paramétricas para el análisis posterior.

Además, se calculó la diferencia entre "Estrés Predicho por IA" y "Estrés Percibido", obteniendo:

- Diferencia (Estrés Predicho por IA - Estrés Percibido): $W = 0.7874, p = 3.89 \times 10^{-5}$

En este caso, el valor p es significativamente menor que 0.05, lo que indica que la diferencia no sigue una distribución normal. Debido a esta falta de normalidad, se aplicará

la prueba no paramétrica de Wilcoxon para comparar las distribuciones del Estrés Predicho por IA y el Estrés Percibido.

3.3.3 Prueba de Wilcoxon

Dada la no normalidad detectada en la diferencia entre las variables "Estrés Predicho por IA" y "Estrés Percibido", se procedió a aplicar la prueba no paramétrica de Wilcoxon para muestras pareadas. Esta prueba se utiliza cuando se desea comparar dos muestras relacionadas, especialmente cuando no se puede asumir que las diferencias siguen una distribución normal.

La prueba de Wilcoxon se basa en el cálculo de las diferencias entre pares de observaciones, las cuales se ordenan por su magnitud absoluta, y se asignan rangos a estas diferencias. Posteriormente, se suman los rangos de las diferencias con signo positivo y las de signo negativo, generando dos sumas W^+ y W^- . El estadístico de prueba W es el menor de estas dos sumas.

3.3.3.1 Datos Utilizados:

Los datos para la prueba se presentan en la tabla 7

Tabla 8

Tabla de datos obtenidos

ID	Estrés Predicho por IA	Estrés Percibido
1	37	38
2	29	28
3	24	23
4	29	28
5	27	28
6	39	37
7	29	28
8	17	18
9	26	27
10	22	24
11	33	31
12	30	28
13	32	34
14	25	27
15	25	23
16	36	35
17	33	35

18	33	35
19	23	21
20	19	20
21	29	31
22	16	18
23	22	24
24	26	24
26	36	34
25	40	38
27	26	24
28	31	29
29	25	24
30	22	24

Fuente: Elaboración propia.

3.3.3.2 Procedimiento:

3.3.3.2.1 Cálculo de las diferencias:

Para cada par de datos (Estrés Predicho por IA - Estrés Percibido), se calculó la diferencia. Estas diferencias se muestran en la tabla 8:

Tabla 9

Cálculo de las diferencias

ID	Estrés Predicho por IA	Estrés Percibido	Diferencias
1	37	38	-1
2	29	28	1
3	24	23	1
4	29	28	1
5	27	28	-1
6	39	37	2
7	29	28	1
8	17	18	-1
9	26	27	-1
10	22	24	-2
11	33	31	2
12	30	28	2
13	32	34	-2
14	25	27	-2

15	25	23	2
16	36	35	1
17	33	35	-2
18	33	35	-2
19	23	21	2
20	19	20	-1
21	29	31	-2
22	16	18	-2
23	22	24	-2
24	26	24	2
25	36	34	2
26	40	38	2
27	26	24	2
28	31	29	2
29	25	24	1
30	22	24	-2

Fuente: Elaboración propia.

Las diferencias fueron calculadas para cada una de las 30 observaciones.

3.3.3.2.2 Ordenamiento y asignación de rangos:

Las diferencias fueron ordenadas según su magnitud absoluta, y se les asignaron rangos.

En casos de diferencias nulas, estas se excluyeron del análisis Tabla 9.

Tabla 10

Ordenamiento y asignación de rangos

ID	Diferencia	Diferencia Absoluta	Rango
1	-1	1	4
2	1	1	4
3	1	1	4
4	1	1	4
5	-1	1	4
6	2	2	12
7	1	1	4
8	-1	1	4
9	-1	1	4
10	-2	2	12
11	2	2	12

12	2	2	12
13	-2	2	12
14	-2	2	12
15	2	2	12
16	1	1	4
17	-2	2	12
18	-2	2	12
19	2	2	12
20	-1	1	4
21	-2	2	12
22	-2	2	12
23	-2	2	12
24	2	2	12
25	2	2	12
26	2	2	12
27	2	2	12
28	2	2	12
29	1	1	4
30	-2	2	12

Fuente: Elaboración propia

3.3.3.2.3 Suma de rangos:

Para calcular el estadístico T de Wilcoxon, necesitamos calcular la suma de los rangos asociados con las diferencias positivas y negativas por separado.

- **Suma de rangos de las diferencias positivas (W+):**

$$4.0+4.0+4.0+4.0+12.0+12.0+12.0+12.0+12.0+12.0+12.0+12.0+12.0+12.0+4.0+12.0+12.0+12.0+12.0+4.0+12.0=246.0$$

- **Suma de rangos de las diferencias negativas (W-):**

$$4.0+4.0+4.0+4.0+4.0+12.0+12.0+12.0+12.0+12.0+12.0+12.0+12.0+12.0+12.0+12.0=219.0$$

3.3.3.2.4 Cálculo del estadístico de Wilcoxon :

El estadístico de Wilcoxon se obtiene como el menor de las sumas de rangos:

$$W = \min (W^+, W^-) = \min(246.0, 219.0) = 219.0$$

3.3.3.3 Resultados:

La aplicación de la prueba de Wilcoxon a los datos proporcionó los siguientes resultados:

- Estadístico de Wilcoxon (W): 219.0
- Valor p: 0.7922

Dado que el valor p es mayor que el nivel de significancia común ($\alpha = 0.05$), no se rechaza la hipótesis nula. Esto indica que no hay una diferencia significativa entre las distribuciones del Estrés Predicho por IA y el Estrés Percibido. En otras palabras, no existe evidencia suficiente para afirmar que las predicciones del modelo de IA difieren de manera significativa de las percepciones de estrés reportadas por los sujetos del estudio.

3.3.3.4 Interpretación:

La prueba de T de Wilcoxon sugiere que el modelo de predicción de estrés basado en IA es coherente con las percepciones de estrés de los individuos. Esto valida la capacidad del modelo para captar las tendencias generales del estrés percibido, aunque podrían existir variaciones individuales no capturadas debido a la naturaleza de los datos y la no normalidad detectada en la diferencia.

3.3.3.5 Análisis Final

El análisis estadístico realizado, que incluyó tanto la prueba de normalidad de Shapiro-Wilk como la prueba no paramétrica de Wilcoxon, proporciona una visión integral sobre la relación entre las predicciones de estrés realizadas por el modelo de IA y las percepciones de estrés reportadas por los sujetos.

Los resultados de la prueba de Shapiro-Wilk confirmaron que las variables "Estrés Predicho por IA" y "Estrés Percibido" siguen una distribución normal, permitiendo el uso de técnicas paramétricas para su análisis. Sin embargo, la diferencia entre estas dos variables no mostró normalidad, lo que justificó el uso de la prueba de T de Wilcoxon para evaluar la coherencia entre las predicciones y las percepciones individuales.

La prueba de T de Wilcoxon sugiere que no existe una diferencia estadísticamente significativa entre las distribuciones del Estrés Predicho por IA y el Estrés Percibido. Este hallazgo es de gran importancia, ya que indica que el modelo de IA utilizado para predecir el estrés se alinea razonablemente bien con las experiencias subjetivas de los participantes. No obstante, es fundamental reconocer que la falta de normalidad en la diferencia entre ambas variables sugiere la presencia de factores individuales o contextuales que podrían influir en la percepción de estrés, los cuales no son completamente capturados por el modelo de predicción.

LIMITACIONES

El presente estudio se desarrolló utilizando datos fisiológicos obtenidos de bases de datos de sensores alrededor del mundo, lo que permitió entrenar el modelo con información biométrica previamente validada en estudios similares. Sin embargo, una limitación importante es que los datos psicológicos, específicamente la Escala de Estrés Percibido (PSS), fueron exclusivamente recolectados de estudiantes de la Universidad Técnica del Norte (UTN). Esto implica que, aunque el modelo se benefició de datos biométricos comparables, la validación del componente psicológico del modelo está restringida a la población de esta universidad.

Esta limitación se traduce en una menor capacidad para generalizar los resultados del análisis del estrés percibido a otras poblaciones estudiantiles o contextos diferentes. Si bien los datos biométricos obtenidos de sensores biométricos son ampliamente aplicables, la falta de una base de datos externa con mediciones de estrés percibido ha limitado el alcance del modelo a la población estudiada en la UTN. Como resultado, el modelo fue optimizado y ajustado principalmente con los datos locales, lo que sugiere la necesidad de recopilar más datos psicológicos de diferentes poblaciones para validar y mejorar su capacidad predictiva en un espectro más amplio de escenarios.

A pesar de estas limitaciones, el modelo proporciona una herramienta valiosa para la detección temprana del estrés en el entorno universitario, pero sería recomendable ampliar el estudio a otros contextos para asegurar su robustez y efectividad a nivel general.

DISCUSIONES

Al desarrollar modelos de predicción de estrés en estudiantes universitarios, es fundamental reconocer que el estrés no solo es una respuesta fisiológica, sino también una experiencia psicológica compleja. Por esta razón, una evaluación efectiva y completa del estrés debe integrar tanto datos fisiológicos como mediciones psicológicas. Los datos fisiológicos, como la frecuencia cardíaca, temperatura corporal y respiración, proporcionan una medida objetiva del impacto del estrés en el cuerpo. Sin embargo, estos datos por sí solos no capturan las percepciones subjetivas del individuo, que son esenciales para entender cómo el estrés es experimentado a nivel mental y emocional.

La inclusión de la Escala de Estrés Percibido (EEP), como la propuesta en esta tesis, permite que se aborde el componente psicológico del estrés. Este enfoque multidimensional es clave, ya que el estrés percibido y el estrés fisiológico no siempre están perfectamente alineados. La integración de ambos tipos de datos mejora significativamente la precisión del modelo, ya que los factores psicológicos, como la percepción del control o la ansiedad relacionada con situaciones académicas, pueden no reflejarse directamente en los indicadores fisiológicos.

Estudios recientes, como WESAD, subrayan la importancia de esta combinación, demostrando que la inclusión de informes subjetivos mejora la capacidad predictiva de los modelos para detectar el estrés en tiempo real (Schmidt et al., 2018). La fortaleza de la relación entre los datos biométricos y las mediciones psicológicas radica en la capacidad de ambos tipos de datos para proporcionar una visión más completa del estado de estrés. Los modelos que solo se basan en datos fisiológicos pueden perder información clave sobre cómo un individuo experimenta internamente el estrés, lo que limita la capacidad de intervención temprana.

Al aplicar tanto datos fisiológicos como psicológicos, el modelo no solo identifica los síntomas físicos del estrés, sino que también reconoce los factores emocionales que pueden influir en la forma en que los estudiantes perciben y gestionan las situaciones estresantes. Este enfoque es particularmente relevante en el contexto académico, donde el estrés crónico puede afectar tanto el bienestar emocional como el rendimiento académico. Como lo destaca el estudio SaYoPillow, la combinación de estos datos permite una gestión más efectiva del estrés, no solo desde una perspectiva física, sino también emocional (Rachakonda et al., 2016).

La fuerte correlación entre los datos biométricos y psicológicos resalta la importancia de emplear ambos enfoques para desarrollar una prueba completa de detección de estrés. En

el caso de los estudiantes universitarios, quienes se enfrentan a múltiples desafíos académicos y personales, la experiencia subjetiva del estrés es tan importante como los signos físicos detectables mediante sensores. Esta correlación también refuerza la idea de que las intervenciones basadas únicamente en datos fisiológicos podrían no ser suficientes para abordar adecuadamente el estrés de los estudiantes.

CONCLUSIONES

- El desarrollo de la aplicación web permitió la detección temprana de estrés en los estudiantes de la UTN, utilizando modelos de aprendizaje automático que integraron tanto datos biométricos como la Escala de Estrés Percibido. La herramienta proporciona un análisis preciso del estrés, permitiendo identificar patrones y niveles de estrés en los estudiantes, lo que facilita la implementación de intervenciones preventivas por parte de la universidad. Con esto, se logra un avance significativo en la creación de un sistema que apoya el bienestar estudiantil y mejora el rendimiento académico.
- El análisis de estudios previos proporcionó una base sólida para el desarrollo de la aplicación. Se identificaron modelos de detección de estrés mediante aprendizaje automático aplicados en poblaciones similares, lo que permitió seleccionar las mejores técnicas. Se encontró que la combinación de datos fisiológicos y psicológicos, como los utilizados en el dataset WESAD y otros estudios revisados, es fundamental para mejorar la precisión en la detección del estrés.
- Se creó un conjunto completo de datos relevantes sobre el nivel de estrés de los estudiantes de la UTN. Los datos incluyeron mediciones biométricas como la frecuencia cardíaca, temperatura corporal y frecuencia respiratoria, así como respuestas de encuestas basadas en la Encuesta de Estrés Percibido 14. Esta información permite entrenar y validar modelos de aprendizaje automático con datos representativos de la población estudiantil, lo que mejora la capacidad predictiva de la aplicación.
- El modelo de IA fue entrenado utilizando algoritmos de aprendizaje automático como Support Vector Machines, Random Forest y XGBoost. Estos modelos fueron comparados en términos de precisión y desempeño. El modelo de Random Forest final mostró una alta capacidad de clasificación de niveles de estrés en estudiantes, con métricas de desempeño sólidas en términos de error cuadrático medio (MSE) y coeficiente de determinación (R^2). Esto confirma la viabilidad del uso de IA para la detección precisa de estrés en estudiantes universitarios.

RECOMENDACIONES

- Se recomienda expandir el conjunto de datos incluyendo la prueba de estrés percibido para entrenar el modelo de inteligencia artificial, incorporando datos de estudiantes de diferentes regiones geográficas y poblaciones diversas. Esta expansión permitirá mejorar la capacidad de generalización del modelo, asegurando que pueda predecir de manera precisa los niveles de estrés en una variedad más amplia de individuos, y no solo en estudiantes de la UTN. Este enfoque contribuirá a reducir el sesgo y a aumentar la aplicabilidad del sistema en otros contextos
- Es esencial seguir validando tanto el dispositivo de recolección de datos como el modelo de IA en colaboración con diferentes disciplinas, como psicología, salud y educación. La validación continua, en entornos controlados y reales, asegurará que las predicciones del modelo sean precisas, mejorando la confianza en los resultados obtenidos. Además, la validación interdepartamental facilitará la integración del sistema en contextos académicos y clínicos.
- Se recomienda implementar y comparar múltiples algoritmos de aprendizaje automático, más allá de los ya utilizados, para analizar el estrés en los estudiantes. La comparación de algoritmos como Redes Neuronales, K-Nearest Neighbors, o Gradient Boosting, entre otros, permitirá identificar cuál se ajusta mejor a las características específicas de los datos recopilados, optimizando la precisión, la eficiencia y el rendimiento del modelo.
- Se recomienda ampliar el modelo para incluir variables adicionales que consideren factores externos, como el entorno social, la situación económica y otros estresores externos que puedan influir en el bienestar emocional de los estudiantes. La incorporación de estas variables permitirá una predicción más integral y precisa del estrés.
- Es recomendable integrar la plataforma de detección de estrés con servicios de apoyo psicológico. Esto permitirá que los usuarios que presenten niveles de estrés altos puedan acceder inmediatamente a recursos de apoyo, lo que puede ser crucial para prevenir el agravamiento de su condición.

BIBLIOGRAFÍA:

- Advancer Technologies. (2013). *Getting Started Using Two 9V Batteries*.
www.AdvancerTechnologies.com
- Álvarez Núñez, A. E., Del, M., Santiago Díaz, C., Zenteno Vázquez, A. C., Catalina, M., Morales, R., Dolores, M., Espinosa, G., Trinidad, G., & Linares, R. (2022). Desarrollo de una metodología para control dinámico de motores con Machine Learning Development of a Methodology for Dynamic Motor Control with Machine Learning. *Research in Computing Science*, 151(12).
- Andrés Jalil, M., & Misas, M. (2007). *Forecast Evaluation of the Exchange Rate Using Artificial Neural Networks and Asymmetric Cost Functions*. 161.
- Andrés Valencia Zambrano, W. (2018). *DISEÑO DE PROTOTIPO “DOCTOR PI” PARA LA MEDICIÓN Y MONITORIZACIÓN DE SIGNOS VITALES EN ADULTOS MAYORES UTILIZANDO SENSORES BIOMÉTRICOS Y MÉDICOS ACOPLADOS A RASPBERRY PI*.
- Antony, M. M., Cox, B. J., Enns, M. W., Bieling, P. J., & Swinson, R. P. (1998). Psychometric properties of the 42-item and 21-item versions of the Depression Anxiety Stress Scales in clinical groups and a community sample. *Psychological Assessment*, 10(2), 176–181.
<https://doi.org/10.1037/1040-3590.10.2.176>
- Autodesk. (2024). *Autodesk Fusion | Software CAD, CAM, CAE y de circuitos impresos 3D basado en la nube | Autodesk*. <https://www.autodesk.com/latam/products/fusion-360/overview?term=1-YEAR&tab=subscription&plc=FSN>
- AWS. (2023a). *¿Qué es una API? - Explicación de interfaz de programación de aplicaciones - AWS*. <https://aws.amazon.com/es/what-is/api/>
- AWS. (2023b). *¿Qué es una red neuronal? - Explicación de las redes neuronales artificiales - AWS*. <https://aws.amazon.com/es/what-is/neural-network/>
- Benhamou, S. (2022). *La transformación del trabajo y el empleo en la era de la inteligencia artificial: análisis, ejemplos e interrogantes*. www.cepal.org/apps
- Campo-Arias, A., Oviedo, H. C., & Herazo, E. (2014). Escala de Estrés Percibido-10: Desempeño psicométrico en estudiantes de medicina de Bucaramanga, Colombia. *Revista de la Facultad de Medicina*, 62(3), 1–24.
<https://doi.org/10.15446/REVFACMED.V62N3.43735>
- Chaptoukaev, H., Strizhkova, V., Panariello, M., D'alpaos, B., Reka, A., Manera, V., Thümmeler, S., Ismailova, E., Evans, N., Bremond, F., Todisco, M., Zuluaga, M. A., &

- Ferrari, L. M. (2023). *StressID: a Multimodal Dataset for Stress Identification*. <https://project.inria.fr/stressid/>.
- Christian, A. (2017). *Heart Rate sensor Galvanic skin response sensor Temperature Scientific Diagram*. https://www.researchgate.net/figure/aHeart-Rate-sensor-bGalvanic-skin-response-sensor-c-Temperature-sensor_fig1_323935725
- cigna. (2023, octubre 11). *Los efectos del estrés y su impacto en tu salud | Cigna Healthcare*. <https://www.cigna.com/es-us/knowledge-center/effects-of-stress-and-their-impact-on-your-health>
- django. (2024). *The web framework for perfectionists with deadlines | Django*. <https://www.djangoproject.com/>
- Eguíluz Pérez, J. (2009). *Introducción a JavaScript*. www.librosweb.es
- Erazo, A., & Galarza, P. (2023). *Vista de La inteligencia artificial aplicada a la optimización de programas informáticos*. <https://economicsocialresearch.com/index.php/home/article/view/61/195>
- espressif. (2023). *ESP32-DevKitC Board I Expressif*. <https://www.espressif.com/en/products/devkits/esp32-devkitc>
- Galán, V., & Castro, E. (2015). *APLICACIÓN DE LA METODOLOGÍA CRISP-DM A UN PROYECTO DE MINERÍA DE DATOS EN EL ENTORNO UNIVERSITARIO*.
- Gikfun. (2024). *Gikfun DS18B20 Waterproof Digital Temperature Sensor with Adapter Modu*. <https://gikfun.com/products/gikfun-ds18b20-waterproof-digital-temperature-sensor-with-adapter-module-for-arduino-pack-of-3-sets>
- GPSLog. (2019). *GPSLog Labs Help - Tracking Heart Rates*. https://gpsloglabs.com/help_heart.html
- Holmes Thomas, & Rahe Richard. (1976). *Escala de reajuste Tomas Holmes y Richard Rahe*.
- hostinger. (2023). *Qué es React: definición, características y funcionamiento*. <https://www.hostinger.es/tutoriales/que-es-react>
- IBM. (2024). *¿Qué es PostgreSQL? | IBM*. <https://www.ibm.com/mx-es/topics/postgresql>
- Krabs, E. (2024). *XGBoost or Logistic Regression model for Diabetes Prediction | by Eason | Medium*. <https://easonlai888.medium.com/xgboost-or-logistic-regression-model-for-diabetes-prediction-1c3670cbbf6e>
- Manuel, G. (2012). *Metodología Scrum*. <https://openaccess.uoc.edu/bitstream/10609/17885/1/mtrigasTFC0612memoria.pdf>

- McCulloch, W. S., & Pitts, W. (1919). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133. <https://doi.org/10.1007/BF02478259>
- medlineplus. (2023). *Signos vitales: MedlinePlus enciclopedia médica*. <https://medlineplus.gov/spanish/ency/article/002341.htm>
- megatronica. (2024). *Pulsador 4 Pines - MEGATRONICA*. <https://megatronica.cc/producto/pulsador-4-pines/>
- Mendoza, L., & Ortega, M. (2010). *Factores que ocasionan estrés en estudiantes universitarios*.
- naylampmechatronics. (2015). *Tutorial LCD con I2C, controla un LCD con solo dos pines*. https://naylampmechatronics.com/blog/35_tutorial-lcd-con-i2c-controla-un-lcd-con-solo-dos-pines.html
- Nkurikiyeyezu, K., Shoji, K., Yokokubo, A., & Lopez, G. (2019). *Thermal Comfort and Stress Recognition in Office Environment*.
- OMS. (2023, octubre). *Stress*. <https://www.who.int/news-room/questions-and-answers/item/stress>
- Palacio, R., Soto, G., Valenzuela, B., & Soltero, A. (2021). *Avances de Investigación en Ingeniería en el Estado de Sonora*.
- Palma, K. (2015). *ESTRÉS ACADÉMICO FACTOR CAUSAL DE GASTRITIS EN ESTUDIANTES DE LA CARRERA DE LICENCIATURA EN ENFERMERÍA*. <https://repositorio.upse.edu.ec/bitstream/46000/1915/1/UPSE-TEN-2015-0006.pdf>
- Pasquel, P., & Pamela, C. (2018). *DISEÑO DE UN SISTEMA DE RECONOCIMIENTO AUTOMÁTICO DE VEHÍCULOS MEDIANTE EL USO DE REDES NEURONALES PROFUNDAS (DNN)*.
- Pérez, D. P., Bustillos, R. S., Mora, C. M., & Botto-Tobar, M. (2020). Prediction of Covid19 with the use of Random Forests Algorithm and Artificial Neural Networks. *Ecuadorian Science Journal*, 4(2), 101–110. <https://doi.org/10.46480/esj.4.2.41>
- Proteus. (2024). *PCB Design and Circuit Simulator Software - Proteus*. <https://www.labcenter.com/>
- Provincial Salud, D. DE, & At Integ Mujer María Elena Bairero Aguilar, M. (2017). *El estrés y su influencia en la calidad de vida*. 21(6).
- pulsesensor. (2023). *Heartbeats in Your Project, Lickety-Split ♥ – World Famous Electronics llc*. <https://pulsesensor.com/>

- Python Software Foundation. (2024). *El tutorial de Python — documentación de Python - 3.12.3*. <https://docs.python.org/es/3/tutorial/>
- Rachakonda, L., Bapatla, A. K., Mohanty, S. P., & Kougianos, E. (2016). *SaYoPillow: Blockchain-Integrated Privacy-Assured IoMT Framework for Stress Management Considering Sleeping Habits*.
- Rachakonda, L., Mohanty, S. P., Kougianos, E., & Sundaravadivel, P. (2019). *Stress-Lysis: A DNN-Integrated Edge Device for Stress Level Detection in the IoMT*.
- Ramos, M., & Fernandez, A. (2019). *PROPIEDADES PSICOMÉTRICAS DE LA ESCALA DE ESTRÉS PERCIBIDO (PSS-14) EN ESTUDIANTES DE BACHILLERATO DE LA PROVINCIA DE TUNGURAHUA (ECUADOR)*. http://www.scielo.org.bo/scielo.php?pid=S2077-21612019000200003&script=sci_arttext
- Researchgate. (2020). *Breathing rate during the meditation Scientific Diagram*. https://www.researchgate.net/figure/Breathing-rate-during-the-meditation-pre-meditative-and-post-baseline-periods-8_fig2_342632998
- Robert L. Spitzer, Janet B.W. Williams, & Kurt Kroenke. (2017). *GDA7_Spanish*.
- Rosa, J. (2020). *Señal EMG medida en los bíceps del brazo derecho Scientific Diagram*. https://www.researchgate.net/figure/Figura-10-a-Senal-EMG-medida-en-los-biceps-del-brazo-derecho-con-los-electrodos-con_fig2_277931231
- Ruiz, F., Agell, N., & Ortega, J. A. (2020). *Proceedings of the XIV ARCA days Qualitative Systems and its Applications in Diagnose, Robotics and Ambient intelligence*.
- Sánchez, E., & Rodríguez, M. (2022). *Implementación de Algoritmos de Inteligencia Artificial para el Entrenamiento de Redes Neuronales de Segunda Generación*. https://www.jovenesenlaciencia.ugto.mx/index.php/jovenesenlaciencia/article/view/715/pdf_2
- Sánchez, J. (2019). *Desarrollo de un entorno digital de aprendizaje desde el Conectivismo y su posterior análisis utilizando algoritmos de machine learning Reconocimiento 4.0*. <https://doi.org/10.21556/edutec.2019.69>
- Schmidt, P., Reiss, A., Duerichen, R., & Van Laerhoven, K. (2018). Introducing WeSAD, a multimodal dataset for wearable stress and affect detection. *ICMI 2018 - Proceedings of the 2018 International Conference on Multimodal Interaction*, 400–408. <https://doi.org/10.1145/3242969.3242985>

- Singh, A., Ganapathysubramanian, B., Singh, A. K., & Sarkar, S. (2016). Machine Learning for High-Throughput Stress Phenotyping in Plants. En *Trends in Plant Science* (Vol. 21, Número 2, pp. 110–124). Elsevier Ltd. <https://doi.org/10.1016/j.tplants.2015.10.015>
- Torres-Lagunas, M. A., Vega-Morales, E. G., Vinalay-Carrillo, I., Arenas-Montaño, G., Rodríguez-Alonzo, E., Torres-Lagunas, M. A., Vega-Morales, E. G., Vinalay-Carrillo, I., Arenas-Montaño, G., & Rodríguez-Alonzo, E. (2015). Validación psicométrica de escalas PSS-14, AFA-R, HDRS, CES-D, EV en puérperas mexicanas con y sin preeclampsia. *Enfermería universitaria*, 12(3), 122–133. <https://doi.org/10.1016/J.REU.2015.08.001>
- Úbeda Romero, J., Cuevas Rodríguez, C., & Berjón Díez Ponente, D. (2020). *MIEMBROS DEL TRIBUNAL Los miembros del tribunal arriba nombrados acuerdan otorgar la calificación de:*
- uelectronics. (2024). *MQ-3 Detector de Alcohol - UNIT Electronics*. <https://uelectronics.com/producto/mq-3-detector-de-alcohol/>
- Universidad Técnica del Norte. (2024). *manual-de-marca-utn*. <https://legislacion.utn.edu.ec/wp-content/uploads/2023/04/manual-de-marca-utn.pdf>
- Vargas, N., & Salazar, H. (2004). *APLICACIÓN DE REDES NEURONALES ARTIFICIALES EN LA PROTECCIÓN DE DISTANCIA EN LÍNEAS DE TRANSMISIÓN*.
- Wang, X., Shi, S., Ali Khan, M. Y., Zhang, Z., & Zhang, Y. (2024). Improving the accuracy of genomic prediction in dairy cattle using the biologically annotated neural networks framework. *Journal of Animal Science and Biotechnology*, 15(1). <https://doi.org/10.1186/S40104-024-01044-1>

ANEXOS

Anexo 1: Certificación medica del dispositivo:

Martha Alicia Cerón Cunguan
Medicina familiar
Instituto Ecuatoriano de seguridad social
Av. Atahualpa y Rumichaca
San Gabriel, Montúfar, Carchi
4/07/2024


Por medio de la presente, certifico que el dispositivo desarrollado para la medición de niveles de estrés ha sido revisado y validado para su uso en contextos académicos y clínicos. Este dispositivo integra las siguientes funcionalidades:

1. **Medición del Pulso:** Utiliza un sensor preciso que registra la frecuencia cardíaca, proporcionando datos en tiempo real sobre las variaciones del ritmo cardíaco, un indicador crucial de la respuesta al estrés.
2. **Medición de la Temperatura:** Equipado con un sensor de temperatura, el dispositivo monitoriza los cambios en la temperatura corporal, otro parámetro significativo en la evaluación de la respuesta fisiológica al estrés.
3. **Medición de la Respiración:** El dispositivo cuenta con un sensor que evalúa la frecuencia y el ritmo respiratorio, ofreciendo una visión completa de la respuesta respiratoria ante situaciones de estrés.

Este dispositivo ha sido diseñado y calibrado para cumplir con las especificaciones necesarias para una medición precisa y fiable de los niveles de estrés. Los sensores utilizados han sido seleccionados por su alta sensibilidad y precisión, garantizando resultados consistentes y reproducibles. Además, el dispositivo ha sido sometido a pruebas rigurosas para asegurar su eficacia y fiabilidad en distintos escenarios y condiciones.

El dispositivo cumple con todas las especificaciones técnicas y de seguridad requeridas para la medición de estrés, proporcionando datos esenciales para estudios académicos y aplicaciones clínicas.

Atentamente,



Martha Alicia Cerón Cunguan
Medicina familiar

Anexo 2: Condigo Arduino del dispositivo

<https://github.com/Isaacmirex/Estresdispositivo>

Anexo 3: Modelos IA entrenados

https://github.com/Isaacmirex/ia_model/tree/main/Data

Anexo 4: Backend Plataforma WEB

https://github.com/Isaacmirex/backen_sensores

Anexo 5: Frontend Plataforma WEB

https://github.com/Isaacmirex/fronted_sensores_utn

Anexo 6: Prueba de estrés percibido EEP14

https://www.cmu.edu/dietrich/psychology/stress-immunity-disease-lab/scales/.doc/pss_14_europeanspanish_dr_remor_version_2_0.doc