



Departamento de Arquitectura de Computadores

# Development of cognitive workload models to detect driving impairment

Memoria presentada por  
**Enriqueta Patricia Becerra Sánchez**

Directores  
**Ph.D. María Angélica Reyes Muñoz**  
**Ph.D. Juan Antonio Guerrero Ibáñez**

Escuela de Ingeniería de Telecomunicaciones y Aeroespacial  
Tesis presentada para obtener el grado de Doctora por la Universidad  
Politécnica de Cataluña

*Castelldefels, 2021*



A mi Madre,  
*Enriqueta Sánchez Bernal*

## RESUMEN

La conducción de un vehículo es una actividad compleja que está expuesta a demandas del entorno vehicular y de las personas que cambian continuamente donde las demandas más frecuentes son los límites de velocidad [1], obstáculos en la vía [2], tráfico vehicular [2], gestión del GPS [3], entre otros. Al desempeñar esta actividad, los conductores requieren un alto grado de concentración incrementando la cantidad de demanda mental conocida como carga cognitiva y provocando al mínimo descuido accidentes vehiculares [4]. De hecho, se ha descubierto que el error humano es el factor principal que contribuye en más del 90% de los accidentes de tráfico y este es causado principalmente por factores que involucran el incremento de la demanda mental del conductor [5].

En los últimos años, se han propuesto mecanismos para monitorear y/o predecir los niveles de carga cognitiva de los sujetos al conducir un vehículo, centrándose en el uso de herramientas subjetivas (autoevaluaciones, cuestionarios, reportes etc.) y de rendimiento vehicular (tasa de error, velocidad, precisión, tiempos de respuesta). Otras investigaciones, han enfatizado en el uso y análisis de la información fisiológica, siendo las señales electroencefalográficas (EEG) las más utilizadas para identificar los estados cognitivos por su alta precisión [4]. A pesar del gran avance realizado, estas investigaciones se han basado en técnicas tradicionales (tales como las técnicas estadísticas) o en el análisis de la información proveniente de fuentes específicas (información recolectada de un sensor) para identificar el estado interno del sujeto, obteniendo modelos predictivos sobreentrenados o robustos, incrementando el tiempo de análisis y procesamiento de la información y afectando el desempeño del modelo predictivo.

Actualmente, se ha abierto una nueva tendencia en el estudio del comportamiento interno de los sujetos, implementando técnicas de aprendizaje automático para crear modelos predictivos capaces de analizar diversos conjuntos de datos provenientes de una o múltiples fuentes. Sin embargo, aún quedan grandes desafíos en esta línea de investigación.

En esta tesis doctoral se presenta un nuevo modelo para predecir los estados de baja y alta carga cognitiva de los sujetos al enfrentarse a escenarios de la conducción de un vehículo denominado GALoRSI-SVMRBF (Genetic Algorithms and Logistic Regression for the Structuring of Information-Support Vector Machine with Radial Basis Function Kernel). GALoRSI-SVMRBF fue desarrollado utilizando los algoritmos de aprendizaje automático y técnicas estadísticas basado en la información proveniente de las señales EEG. También, fue implementada en el modelo la información del auto-reporte NASA-TLX (Task Load Index), la autoevaluación instantánea en línea (ISA) y una métrica de desempeño vehicular.

Primero, GALoRSI-SVMRBF crea una base de datos extrayendo las características que serán utilizadas en el modelo a través de técnicas estadísticas. Posteriormente, propone un nuevo método para el reconocimiento de patrones basado en la selección de características que combina pruebas estadísticas, algoritmos genéticos y regresión logística. Este método consiste principalmente en seleccionar un conjunto de datos EEG y explorar la combinación de la



información para identificar las características claves que contribuyan al reconocimiento de dos estados cognitivos. Después, la información seleccionada es definida como un índice para el reconocimiento de patrones y utilizada para estructurar un nuevo conjunto de datos que soporta información de uno o múltiples canales para optimizar el proceso de aprendizaje y clasificación del modelo.

Por último, es desarrollado el clasificador del modelo de predicciones el cual consiste en dos etapas definidas como entrenamiento y prueba. La etapa de entrenamiento consiste en aprender el comportamiento de la información donde es utilizado el 90% de los datos. La etapa de prueba es donde se evalúa la capacidad predictiva del modelo entrenado utilizando el 10% de los datos restantes. Fue utilizada la técnica de validación cruzada k-fold ( $k=5$ ) para dividir los datos utilizados en cada etapa evitando problemas de sobreajuste en el modelo.

En esta tesis, también se presentan el análisis de validación y evaluación del desempeño de GALoRSI-SVMRBF. El análisis de validación evalúa la capacidad de adaptación del modelo a nuevos conjuntos de datos conservando una alta tasa de predicción. El análisis de evaluación del desempeño del modelo consiste en analizar sus alcances y limitaciones para encontrar el óptimo ajuste de configuración de GALoRSI-SVMRBF. En ambos análisis, fueron utilizadas dos bases de datos internacionales de señales EEG.

Nosotros encontramos que GALoRSI-SVMRBF predice de manera exitosa la carga cognitiva baja y alta de los sujetos durante la conducción de un vehículo. En general, se observó que el modelo utiliza la información extraída de una o múltiples señales EEG, reduciendo el conjunto de datos original en más del 50%, maximizando su capacidad predictiva y logrando una tasa de precisión  $>90\%$  en la clasificación de la información [6].

Así mismo, los resultados de los experimentos realizados durante esta tesis demostraron que obtener un alto porcentaje de predicción depende de varios factores, que van desde aplicar una buena técnica de recolección de los datos hasta la última etapa del modelo de predicción.

Además, en esta investigación se presenta un nuevo protocolo de experimentación desarrollado para recolectar la información fisiológica, subjetiva y de rendimiento vehicular de los sujetos al enfrentarse a un escenario de conducción vehicular. También, en esta tesis se aborda uno de los principales problemas que presentan los investigadores al trabajar con señales EEG: el alto nivel de sensibilidad en la señal para capturar ruido y artefactos generados por el movimiento corporal, el cual incrementa continuamente al grabar la señal en un entorno real como es la conducción de un vehículo. Para afrontar estos problemas, en este trabajo se presenta el desarrollo de dos interfaces Cerebro-Computadora. La primera interfaz recolecta la información de la señal EEG de los sujetos en tiempo real durante la conducción de un vehículo. La segunda interfaz permite procesar y extraer las características más relevantes en el contexto de la carga cognitiva utilizadas para identificar los estados cognitivos de los sujetos.

**Palabras claves:** aprendizaje automático, modelo de predicción, carga cognitiva, señales EEG.

## ABSTRACT

Driving a vehicle is a complex activity exposed to the demands of the vehicular environment and people, which continually change where the most frequent demands are speed limits [1], obstacles on the road [2], vehicular traffic [2], GPS management [3], among others. Drivers require a high degree of concentration when performing this activity, increasing the amount of mental demand known as cognitive workload, causing vehicular accidents to the minimum negligence [4]. In fact, human error is the leading contributing factor in over 90% of road accidents [5].

In recent years, the subjects' cognitive workload levels while driving a vehicle have been predicted using subjective and vehicle performance tools. Other research has emphasized the use and analysis of physiological information, where electroencephalographic (EEG) signals are the most used to identify cognitive states due to their high precision [4]. Although significant progress has been made in this area, these investigations have been based on traditional techniques or data analysis from a specific source due to the information's complexity. A new trend has been opened in the study of the internal behavior of subjects by implementing machine learning techniques to analyze information from various sources. However, there are still several challenges to face in this new line of research.

This doctoral thesis presents a new model to predict the states of low and high cognitive workload of subjects when facing scenarios of driving a vehicle called GALoRSI-SVMRBF (Genetic Algorithms and Logistic Regression for the Structuring of Information-Support Vector Machine with Radial Basis Function Kernel). GALoRSI-SVMRBF is developed using machine learning algorithms based on information from EEG signals. Also, the information collected from NASA-TLX (Task Load Index), instant online self-assessment (ISA) and the error rate measure are implemented in the model.

First, GALoRSI-SVMRBF proposes a new method for pattern recognition based on feature selection that combines statistical tests, genetic algorithms, and logistic regression. This method consists mainly of selecting an EEG dataset and exploring the information to identify the key features that recognize cognitive states. The selected data are defined as an index for pattern recognition and used to structure a new dataset capable of optimizing the model's learning and classification process [6].

Second, the methodology and development of a classifier for the prediction model are presented, implementing machine learning algorithms. The classifier is developed mainly in two phases, defined as training and testing. The training consists of introducing a dataset where the model learns the behavior of the information. The testing phase is where the model's predictive ability is evaluated by using a new dataset.

Once the prediction model has been developed, this thesis presents the validation phase of GALoRSI-SVMRBF. The validation consists of evaluating the model's adaptability to new

datasets, maintaining a high prediction rate. An international database related to vehicles' driving in a simulated environment recognized in the scientific field is implemented.

Finally, an analysis of the performance of GALoRSI-SVMRBF is presented. The objective is to know the model's scope and limitations, evaluating various performance metrics to find the optimal configuration for GALoRSI-SVMRBF.

We found that GALoRSI-SVMRBF successfully predicts low and high cognitive workload of subjects while driving a vehicle. In general, it is observed that the model uses the information extracted from multiple EEG signals, reducing the original dataset by more than 50%, maximizing its predictive capacity, achieving a precision rate of  $>90\%$  in the classification of the information [6]. During this thesis, the experiments showed that obtaining a high percentage of prediction depends on several factors, from applying a useful collection technique data until the last step of the prediction model.

In addition, this research presents a new experimentation protocol developed to collect physiological, subjective and vehicle performance information from subjects when facing a vehicle driving scenario. This thesis also addresses one of the main problems that emerge when working with EEG signals: the high level of sensitivity in the signal to capture noise and artifacts generated by body movement, which continuously increases when recording the signal in an environment such as driving a vehicle. This work presents the development of two Brain-Computer interfaces to collect the EEG signal in real-time while driving a car and extract the most relevant features to identify the different levels of cognitive states of the subjects.

**Keywords:** Machine Learning, Prediction Model, Cognitive Workload, EEG signals.

## **AGRADECIMIENTOS**

Quiero agradecer a mis directores de tesis, a la Dra. Angélica Reyes y al Dr. Tony Guerrero por el apoyo otorgado para el desarrollo de esta tesis. Mi agradecimiento al grupo de investigación ICARUS por permitirme participar en sus proyectos e investigaciones durante mi doctorado.

Me gustaría agradecer a mis compañeros y amigos Cecilia, Enrique, Siddharth, Prem, Vu, Kiyo, Horacio y Alex por todo el apoyo y soporte que me dieron durante mi doctorado. También, quiero agradecer a mis amigos de toda la vida que me apoyaron desde la distancia.

Quiero agradecer a mi familia francesa Michéle y Bernard por el apoyo incondicional y los consejos dados en todo momento.

Agradezco infinitamente a Claude Renaut por su soporte, amor, confianza y sobre todo por creer en mí en todo momento.

Finalmente, mi especial agradecimiento a mi familia. A mi tía Patricia por su confianza. A mis hermanas Ericka y Heidi por ser mi ejemplo a seguir. A mi hermano Paco por ser mi inspiración. A mi padre Francisco que me aconseja desde la distancia y en especial a mi madre Enriqueta por ser el pilar de mi vida y estar siempre conmigo en los mejores y peores momentos con sus sabios consejos.

¡Muchas gracias a todos!

## ÍNDICE

<b>INTRODUCCIÓN .....</b>	<b>1</b>
1. HIPÓTESIS .....	3
2. OBJETIVOS .....	3
2.1. Objetivo General.....	3
2.2. Objetivos Específicos.....	4
3. PROBLEMA DE INVESTIGACIÓN.....	4
4. PRINCIPALES APORTACIONES DE ESTE TRABAJO DE INVESTIGACIÓN .....	5
5. RESULTADOS OBTENIDOS DE LA TESIS .....	6
5.1. Lista de Publicaciones.....	6
5.2. Colaboración.....	6
5.3. Seminario.....	7
5.4. Reporte.....	7
6. ESTRUCTURA DEL DOCUMENTO.....	7
<b>ANTECEDENTES.....</b>	<b>9</b>
1. CARGA COGNITIVA .....	9
1.1. Herramientas para Evaluar la Carga Cognitiva.....	9
1.1.1. Medidas Subjetivas .....	10
1.1.2. Medidas de Rendimiento.....	10
1.1.3. Medidas Fisiológicas .....	10
2. APRENDIZAJE AUTOMÁTICO.....	11
2.1. Fases para el Desarrollo de un Modelo de Aprendizaje Automático.....	12
2.1.1. Preprocesamiento de los Datos.....	12
2.1.2. Selección de Características.....	12
2.1.3. Selección del Algoritmo.....	12
2.1.4. Entrenamiento del Modelo.....	12
2.1.5. Validación .....	13
3. ENFOQUES DE APRENDIZAJE AUTOMÁTICO.....	13
3.1. Algoritmos Supervisados.....	13
3.2. Algoritmos no Supervisados.....	16
4. CONCLUSIONES.....	16
<b>PRIMERA FASE DEL DESARROLLO DEL MODELO DE PREDICCIONES: RECOLECCIÓN Y EXTRACCIÓN DE LA INFORMACIÓN PARA EL MODELO DE PREDICCIONES .....</b>	<b>19</b>
1. INTRODUCCIÓN .....	19
2. METODOLOGÍA.....	21
2.1. Adquisición de los Datos .....	23
2.2. Extracción de Características.....	23
2.3. Preprocesamiento .....	25
2.4. Procesamiento.....	28
3. EXPERIMENTOS.....	29
3.1. Sujetos Experimentales.....	29

3.2.	Procedimiento Experimental.....	29
4.	CONFIGURACIONES.....	30
4.1.	Métricas y Parámetros.....	30
5.	RESULTADOS.....	31
6.	DISCUSIÓN .....	33
7.	CONCLUSIONES.....	33

**SEGUNDA FASE DEL DESARROLLO DEL MODELO DE PREDICCIONES:**

**SELECCIÓN DE CARACTERÍSTICAS Y DESARROLLO DEL CLASIFICADOR ..... 36**

1.	INTRODUCCIÓN .....	36
2.	METODOLOGÍA.....	40
2.1.	Análisis Estadístico.....	41
2.2.	GALoRSI.....	42
2.2.1.	Población .....	42
2.2.2.	Función de Ajuste .....	44
2.2.3.	Selección .....	47
2.2.4.	Cruce .....	48
2.2.5.	Mutación .....	48
2.2.6.	Normas de Detección.....	49
2.3.	Estructuración de la Información.....	49
2.4.	Clasificadores .....	50
2.5.	Etiqueta .....	51
3.	EXPERIMENTACIÓN Y MATERIALES .....	52
3.1.	Diseño del Experimento .....	52
3.2.	Medidas Subjetivas .....	53
3.3.	Medidas de Rendimiento Vehicular.....	54
3.4.	Recolección y Extracción de las Señales EEG .....	54
3.5.	Conjunto de Datos y Parámetros.....	56
4.	RESULTADOS.....	59
4.1.	Medidas Subjetivas .....	59
4.2.	Medidas de Rendimiento Vehicular.....	60
4.3.	Señales EEG .....	60
4.4.	Resultados de la Prueba Estadística.....	60
4.5.	Técnica de Etiquetado .....	62
4.6.	Resultados de GALoRSI.....	62
4.7.	Resultados del Clasificador .....	64
5.	DISCUSIONES Y CONCLUSIONES.....	65

**TERCERA FASE DEL DESARROLLO DEL MODELO DE PREDICCIONES:**

**VALIDACIÓN DEL MODELO DE PREDICCIONES DE ESTADOS COGNITIVOS..... 70**

1.	INTRODUCCIÓN .....	70
2.	GALoRSI-SVMRBF .....	73
3.	SEED-VIG.....	75
3.1.	Procesamiento y Estructuración de SEED-VIG .....	77
3.2.	Parámetros del Modelo.....	78
4.	RESULTADOS.....	79
5.	DISCUSIONES Y CONCLUSIONES.....	85

<b>ANÁLISIS DEL DESEMPEÑO DEL MODELO DE PREDICCIONES DE ESTADOS COGNITIVOS.....</b>	<b>89</b>
1. INTRODUCCIÓN .....	89
2. MÉTRICAS .....	90
2.1. Exactitud.....	90
2.2. Tiempo de procesamiento.....	91
2.3. Escalabilidad.....	91
3. HERRAMIENTAS Y PARÁMETROS .....	92
3.1. Parámetros del Modelo.....	92
3.2. Hardware .....	92
3.3. Bases de Datos DEAP.....	92
3.4. Procesamiento y Estructuración de DEAP.....	94
4. RESULTADOS Y DISCUSIONES .....	94
4.1. Resultados de SVMRBF .....	95
4.2. Resultados de SVMLineal .....	96
4.3. Resultados de k-NN.....	99
4.4. Resultados de RL.....	99
4.5. Resultados de la Exactitud .....	103
4.6. Resultados del Tiempo de Procesamiento.....	104
4.7. Resultados del Escalabilidad .....	106
5. CONCLUSIONES.....	106
<b>CONCLUSIONES Y TRABAJOS FUTUROS.....</b>	<b>109</b>
1. CONCLUSIONES DE LA TESIS.....	109
2. TRABAJOS FUTUROS .....	111
3. BASES DE DATOS DISPONIBLES .....	111
4. REPOSITARIOS.....	111
<b>REFERENCIAS.....</b>	<b>112</b>

## ÍNDICE DE FIGURAS

Figura 1 Hiperplano bidimensional del algoritmo SVM [66] .....	14
Figura 2 Diagrama del modelo para detectar altos o bajos niveles de carga cognitiva del conductor .....	22
Figura 3 Datos generados de las señales EEG .....	23
Figura 4 Panel frontal de la recolección de las señales EEG .....	25
Figura 5 Diagrama de Bloques de la extracción de las cinco características espectrales de las señales EEG .....	26
Figura 6 Datos de entrada del modelo de predicción.....	30
Figura 7 Matriz de confusión de los clasificadores SVM, RL y k-NN.....	32
Figura 8 Diagrama del modelo para predecir de estados de carga cognitiva alta y baja de conductor del vehículo.....	41
Figura 9 Creación de la población y evaluación .....	42
Figura 10 Arquitectura del modelo GALoRSI para el reconocimiento de patrones basado en algoritmos genéticos y regresión logística .....	43
Figura 11 Estructura del cromosoma conformado por la información de los genes seleccionados y el peso de cada .....	44
Figura 12 Código de la Función de Ajuste.....	46
Figura 13 Selección y organización de los cromosomas basado en los parámetros NA.....	47
Figura 14 Sistema de selección de elementos para construir nuevos cromosomas con mejores propiedades.....	48
Figura 15 Modelo de estructuración de la información basado en el cromosoma construido por GALoR .....	50
Figura 16 Adquisición de la señal EEG en tiempo real. ....	55
Figura 17 Interfaz desarrollada para extraer las cinco bandas de frecuencia de las señales EEG .....	56
Figura 18 Conjunto de datos 1 del modelo de predicciones .....	58
Figura 19 Análisis del desempeño de GALoR evaluando diferentes tamaños de poblaciones y generaciones. ....	59
Figura 20 Comparación de resultados obtenidos con otros algoritmos parecidos a GALoRSI-SVM en la literatura.....	67
Figura 21 Modelo de predicción de estados emocionales basado en algoritmos evolutivos computacionales y PNN.....	71
Figura 22 Diagrama de la técnica de selección de características RNCA .....	72
Figura 23 Mecanismo para reducir la dimensionalidad del conjunto de datos de las señales EEG.....	72



Figura 24 Fase de experimentación de SEED a) simulación de la conducción, b) participante portando los sensores para la recolección de la información EEG y EOG, c) experimentación en curso [178] .....	77
Figura 25 Análisis del desempeño del modelo.....	79
Figura 26 Resultados obtenidos del S1 con SEED-VIG donde en (a)SVMRBF (b)SVML (c)k-NN y (d) RL .....	81
Figura 27 Tasa de selección de la información basado en GALoRSI-SVMRBF para identificar las características relevantes de SEED-VIG.....	83
Figura 28 Predicción de nuevos conjuntos de datos de entrada del modelo GALoRSI-SVMRBF entrenado .....	84
Figura 29 Modelos relacionados a este trabajo implementando SEED-VIG.....	85
Figura 30 Evaluación del desempeño del modelo analizando diferentes configuraciones....	92
Figura 31 Sistema de autoevaluación SAM [198] .....	93
Figura 32 Cuadrante cognitivo bidimensional (a) Alta/Baja Valencia y (b) Alta/Baja Excitación [199] .....	93
Figura 33 Análisis del desempeño del GALoRSI-SVMRBF en la fase de entrenamiento ....	97
Figura 34 Análisis del desempeño del GALoRSI-SVMRBF en la fase de prueba.....	97
Figura 35 Análisis del desempeño del GALoRSI-SVMLineal en la fase de entrenamiento..	98
Figura 36 Análisis del desempeño del GALoRSI-SVMLineal en la fase de prueba .....	99
Figura 37 Análisis del desempeño del GALoRSI-k-NN en la fase de entrenamiento .....	101
Figura 38 Análisis del desempeño del GALoRSI-k-NN en la fase de prueba.....	102
Figura 39 Análisis del desempeño del GALoRSI-RL en la fase de entrenamiento .....	102
Figura 40 Análisis del desempeño del GALoRSI-RL en la fase de prueba.....	102
Figura 41 Comparación de modelos de predicción desarrollados con DEAP.....	103
Figura 42 Tiempo de procesamiento en fase de entrenamiento .....	105
Figura 43 Tiempo de procesamiento en fase de prueba .....	105
Figura 44 Tasa de exactitud por conjunto de datos.....	106
Figura 45 Panel de control del sensor Emotiv EPOC .....	121
Figura 46 Colocación del sensor Emotiv EPOC .....	122
Figura 47 Panel de control para la visualización y almacenamiento de las señales EEG ...	122
Figura 48 Diagrama de bloques de la visualización de las señales EEG .....	123
Figura 49 Archivo generado de la recolección de las señales EEG .....	124
Figura 50 Acuerdo presentado a cada participante antes de iniciar los experimentos .....	125

## ÍNDICE DE TABLAS

Tabla 1 Relación de las bandas de frecuencias con respecto a la actividad cerebral [48].....	11
Tabla 2 Resultados del modelo de predicción .....	32
Tabla 3 Índices para calcular diversos estados de las personas utilizando las bandas de frecuencia .....	51
Tabla 4 Conjuntos de datos contruidos para analizar el comportamiento de la información .....	57
Tabla 5 Resultado de la prueba ISA y NASA-TLX.....	59
Tabla 6 Resultados de la prueba TE.....	60
Tabla 7 Análisis Descriptivo de las señales EEG.....	60
Tabla 8 Resultados de la prueba T-Student.....	61
Tabla 9 Resultados de la prueba de la correlación de Pearson en las medidas subjetivas, rendimiento vehicular y señales EEG .....	61
Tabla 10 Intervalos de valores para categorizar los datos en los siete conjuntos de datos....	62
Tabla 11 Resultados de GALoRSI .....	64
Tabla 12 Resultados obtenidos con los clasificadores SVMRBF, SVMLineal, k-NN y LR..	65
Tabla 13 Resultados del desempeño de los cuatro clasificadores que utilizan los algoritmos GALoRSI, Información Mutua (MI) y Análisis de Componentes Principales (PCA).....	65
Tabla 14 Algoritmo de modelo de predicciones GALoRSI-SVMRBF .....	76
Tabla 15 Estructura de datos SEEG-VIG construida para el análisis de GALoRSI-SVMRBF .....	78
Tabla 16 Tabla de parámetros implementados en el modelo.....	79
Tabla 17 Resultados de SEED-VIG .....	81
Tabla 18 Estructura de datos DEAP construida para el análisis de GALoRSI-SVMRBF....	95
Tabla 19 Resultados obtenidos de evaluar el modelo GALoRSI utilizando SVMRBF .....	96
Tabla 20 Resultados obtenidos de evaluar el modelo GALoRSI utilizando SVMLineal.....	98
Tabla 21 Resultados obtenidos de evaluar el modelo GALoRSI utilizando k-NN .....	100
Tabla 22 Resultados obtenidos de evaluar el modelo GALoRSI utilizando RL .....	101
Tabla 23 Tiempo de Procesamiento de los Algoritmos utilizando las señales EEG.....	104

## ÍNDICE DE ANEXOS

Anexo A: Adquisición de las Señales EEG Utilizando el sensor Emotiv y la Herramienta LabView .....	121
Anexo B: Hoja de Consentimiento para realizar los Experimentos.....	125
Anexo C: Resultados Obtenidos de Aplicar GALoRSI en SEED-VIG .....	126

## ACRÓNIMOS

**EEG** - Electroencefalograma

**ML** - Machine Learning

**AA** - Aprendizaje Automático

**BCI** - Brain Computer Interface

**HR** - Heart Rate

**EOG** - Electrooculogram

**SVM** - Support Vector Machine

**k-NN** - k Nearest Neighbors

**LR** - Linear Regression

**PSD** -Power Spectral Density

**FFT** - Fast Fourier Transform

**RBF** - Radial Basis Function

**RL** - Regresión Lineal

**NASA-TLX** -Task Load Index

**ISA** - Instantaneous Self-Assessment

**TE** - Tasa de Error

**ASC** - Algoritmos de Selección de Características

**GALoRSI** - Genetic Algorithm and Logistic Regression for the Structuring of Information

**AG** - Algoritmos Genéticos

**RLo** - Regresión Logística

**FA** - Función de Ajuste

**NA** - Números de Adaptación

**CCB** - Correctamente Carga Cognitiva Baja

**ICA** - Incorrectamente Carga Cognitiva Alta

**CCA** - Correctamente Carga Cognitiva Alta

**ICB** - Incorrectamente Carga Cognitiva Baja

**LCT** - Lane Change Test

**MI** - Mutual Information

**PCA** - Principal Component Analysis



# CAPÍTULO I

## INTRODUCCIÓN

La conducción de un vehículo es una actividad compleja que está expuesta a demandas del entorno vehicular y de las personas que cambian continuamente donde las demandas más frecuentes son los límites de velocidad [1], obstáculos en la vía [2], tráfico vehicular [2], gestión del GPS [3], entre otros. Al desempeñar esta actividad, los conductores requieren un alto grado de concentración, incrementando la demanda en la carga cognitiva provocando accidentes vehiculares al mínimo descuido [4].

Recientemente se han implementado tecnologías vehiculares (tales como, detección de peatones y estacionamiento automático) para mejorar la seguridad y la experiencia de los sujetos durante la conducción [7]. Sin embargo, una gran desventaja en estas tecnologías vehiculares es que no incluyen la detección de la carga cognitiva del conductor.

Por otro lado, muchas investigaciones se han centrado en el análisis y desarrollo de modelos para evaluar la demanda de la carga cognitiva de los sujetos al realizar diversas actividades. Estos modelos suelen ser principalmente modelos estadísticos, matemáticos y computacionales, como en [8] proponen un modelo para analizar el comportamiento de los sujetos al conducir un vehículo, en [9] desarrollan un modelo para analizar el desempeño de una persona al realizar tareas de seguimiento, en [10] proponen un modelo para analizar el comportamiento de una persona al tocar un instrumento y en [11] desarrollan un modelo matemático para analizar el aprendizaje de los alumnos en las aulas. Estos modelos se han basado principalmente en el estudio y análisis de las medidas subjetivas (tales como, NASA-TLX, SWAT o SCAN), así como también, de las medidas de rendimiento (tales como, tasa de error, tiempo de reacción, entre otros) para examinar la interpretación de la carga cognitiva de una persona basada en su opinión o auto-evaluación y en su capacidad para mantener un sistema dentro de los márgenes de seguridad aceptables.

Algunas otras investigaciones, han destacado por implementar medidas fisiológicas como Electroencefalográficas (EEG), Electrocardiograma (ECG) y Electrooculograma (EOG) para identificar los estados de alta o baja carga cognitiva con precisión. Por ejemplo, en [8] los autores utilizan métodos estadísticos para evaluar la carga cognitiva de los sujetos en un entorno de conducción simulado. En este modelo no implementaron medidas fisiológicas como EEG o EOG caracterizadas por identificar con precisión el estado cognitivo de los sujetos. En [12] los

autores proponen un modelo matemático para detectar la carga cognitiva de los sujetos al conducir un vehículo. La información del movimiento ocular, auto-evaluaciones y pedales del vehículo implementadas en el modelo no identificaron eficientemente los cambios de estados cognitivos de los sujetos. En [13] los autores desarrollaron un modelo para predecir la carga cognitiva de los conductores de vehículos implementando una función de discriminación lineal. Los resultados demostraron que la medida de ritmo cardíaco no fue capaz de detectar eficientemente la carga cognitiva de los sujetos en comparación con las medidas de rendimiento utilizadas en el modelo, tales como, velocidad del aire y altitud. En [14] se presenta un modelo basado en la entropía de la información utilizando principalmente las señales EEG para predecir la carga cognitiva de los sujetos. El modelo presentó un 57% de precisión en la predicción al combinar la información del movimiento ocular, NASA-TLX y las señales EEG en comparación con un 90% al implementar la información de una sola fuente. En [15] proponen un modelo basado en técnicas estadísticas para predecir la carga cognitiva de los sujetos. Las señales EEG no identificaron eficientemente los cambios de estados cognitivos debido al exceso del esfuerzo mental requerido durante el experimento. En [16] diseñaron un modelo basado en el análisis de la discriminación lineal para predecir estados cognitivos. La información de la señal EEG y la combinación de EEG+fNIRS (functional near-infrared spectroscopy) como datos de entrada en el modelo no mejoraron significativamente la clasificación de la carga cognitiva. En [17] los autores desarrollaron un modelo basado en la técnica de la información mutua para estimar la carga cognitiva. El modelo obtuvo un bajo rendimiento al utilizar información de una fuente específica.

Los principales problemas a los que se enfrentan los modelos antes mencionados se deben a que no implementan técnicas para identificar la información clave que sea capaz de analizar o describir el estado cognitivo de interés al utilizar las señales EEG. Al identificar la información exacta, permitirá a su vez eliminar información redundante o información que no es relevante para el análisis y a su vez maximizar el rendimiento predictivo del modelo. Algunas investigaciones, consideran una porción limitada de características, información reducida o datos provenientes de una fuente específica donde la información es seleccionada aleatoriamente y no es capaz de identificar el estado interno del sujeto que se desea analizar. Por el contrario, otras investigaciones se han basado en técnicas tradicionales (técnicas estadísticas, análisis de componentes principales, kernel, análisis discriminante lineal, entre otros) para identificar información clave, sin considerar implementar análisis o modelos sofisticados para estudiar datos complejos, como son las señales EEG. Esto incrementa el tiempo de análisis y procesamiento de la información, obteniendo modelos robustos, complejos y con una baja tasa de rendimiento.

En esta tesis, se presenta el desarrollo de un nuevo modelo de predicciones denominado Genetic Algorithms and Logistic Regression for the Structuring of Information-Support Vector Machine with kernel RBF (GALoRSI-SVMRBF) basado en el algoritmo genético, aprendizaje automático y técnicas estadísticas, el cual consiste en buscar, seleccionar, estructurar y clasificar

la información para detectar y predecir los niveles de baja y alta carga cognitiva de los sujetos al realizar actividades que involucran la interacción de tipo Máquina-Sujeto como es la conducción de un vehículo.

GALoRSI-SVMRBF combina algoritmos genéticos (AG), regresión logística (RLo) y análisis estadísticos para crear una nueva función de ajuste que permita explorar y evaluar la información, identificando las características claves que contribuyan al reconocimiento de los estados cognitivos, generando una nueva estructura de datos basada principalmente en la calidad y en la coherencia de la información. El nuevo conjunto de datos es utilizado como un índice para el reconocimiento de patrones que optimiza el proceso de entrenamiento y aprendizaje del modelo obteniendo una tasa de predicción >90%.

El modelo desarrollado en esta investigación utiliza la información fisiológica proveniente de las señales Electroencefalográficas (EEG) caracterizadas por identificar con precisión el estado interno del sujeto. Además, es implementada la información de las medidas subjetivas y de rendimiento vehicular con el objetivo de analizar y estudiar la relación del comportamiento de los datos recolectados de manera interna (señales EEG) y externa (medidas subjetivas y de rendimiento vehicular) del sujeto para optimizar la fase de aprendizaje del modelo.

En los siguientes apartados se presenta a detalle las hipótesis, objetivos, aportaciones y resultados obtenidos en este trabajo de investigación.

## **1. HIPÓTESIS**

En esta tesis se proponen las siguientes hipótesis de investigación

- El modelo de predicciones GALoRSI-SVMRBF es capaz de identificar la información de las señales EEG para detectar niveles de baja y alta carga cognitiva.
- El modelo de predicciones GALoRSI-SVMRBF predice de manera eficiente los estados de baja y alta carga cognitiva de los sujetos durante la conducción de un vehículo.

## **2. OBJETIVOS**

### **2.1. Objetivo General**

El objetivo principal de esta tesis es desarrollar un modelo basado en algoritmos de aprendizaje automático para detectar y predecir de manera eficiente los estados de baja y alta carga cognitiva de los sujetos al conducir un vehículo utilizando la información de las señales EEG.

## 2.2. Objetivos Específicos

**Obj. 1:** Desarrollar un sistema que permite recolectar y procesar la información de las señales EEG en tiempo real.

**Obj. 2:** Desarrollar un índice de carga cognitiva basado en señales EEG para detectar estados de baja y alta carga cognitiva.

**Obj. 3:** Desarrollar una técnica de selección de características para el reconocimiento de patrones capaz de identificar la información que describa los estados de baja y alta carga cognitiva.

**Obj. 4:** Desarrollar un clasificador utilizando los algoritmos de aprendizaje automático basado en la información de las señales EEG.

**Obj. 5:** Validar el modelo desarrollado con nuevos conjuntos de datos de señales EEG.

## 3. PROBLEMA DE INVESTIGACIÓN

Construir un modelo de predicciones basado en la información de las señales EEG, es una tarea difícil que involucra diversos aspectos que se tienen que considerar para su desarrollo. Primero, se deben abordar varios problemas metodológicos que van desde la recolección de los datos hasta el desarrollo de sofisticados algoritmos capaces de realizar predicciones con una alta tasa de precisión donde entender el diseño del modelo resulta complejo debido a su desconocido funcionamiento interno que mantiene una naturaleza opaca y no explica con claridad el modelado de la información en cada una de las fases del modelo para lograr obtener resultados predictivos concretos.

Por otro lado, es importante considerar los retos que representa trabajar con las señales EEG donde uno de los principales problemas que enfrentan los investigadores es identificar elementos que tengan un impacto significativo a la hora de describir un estado cognitivo. Esto se debe principalmente a la alta dimensionalidad de la señal EEG causada por las técnicas utilizadas para el tratamiento de la señal que permiten extraer características que describen el comportamiento del sujeto incrementando exponencialmente el volumen de los datos. A esto, se debe sumar que las señales EEG son recolectadas por diversas zonas de la corteza cerebral, obteniendo grandes conjuntos de datos que a su vez van incrementando conforme a la cantidad de sensores que tiene el dispositivo y al tiempo de sensado. Al obtener grandes volúmenes de datos de entrada, incrementa el tiempo de análisis y procesamiento de la información llevando a la necesidad de desarrollar modelos más sofisticados, robustos y complejos que requieren en muchos de los casos equipos específicos para poder realizar el análisis de los datos.

Aunque es sabido que los grandes volúmenes de datos son la clave para encontrar la solución al problema que se está tratando de resolver, también, representan la parte más costosa y compleja desde el punto de vista computacional y algorítmico, sobretodo al hablar de sistemas



en tiempo real. Por ello, es importante desarrollar modelos predictivos claros que permitan analizar su desempeño encontrando el balance entre datos, procesos y resultados.

Con base en el dominio del problema se abren las siguientes preguntas de investigación de esta tesis

- ¿Las señales EEG pueden ser utilizadas para predecir la carga cognitiva baja y alta de los conductores de vehículos de manera eficiente?
- ¿Se pueden determinar características claves de las señales EEG que describan los estados de baja y alta carga cognitiva de las personas durante la conducción de un vehículo?
- ¿Se puede desarrollar un modelo predictivo enfocado en la selección, estructuración y clasificación de los datos para optimizar el análisis de la información y el desempeño del modelo, enfrentando los principales problemas de las señales EEG?

#### **4. PRINCIPALES APORTACIONES DE ESTE TRABAJO DE INVESTIGACIÓN**

- Se desarrolló un nuevo protocolo de experimentación para recolectar la información fisiológica, subjetiva y de rendimiento vehicular de los sujetos al enfrentarse a un escenario de conducción vehicular.
- Fueron desarrollados dos sistemas BCI (Brain Computer Interface).
  - El primer sistema recolecta y almacena la señal EEG en tiempo real.
  - El segundo sistema procesa la información EEG para extraer las características que ayudarán a identificar carga cognitiva.
- Se desarrolló una metodología de validación de señales EEG utilizando técnicas estadísticas basadas en las medidas subjetivas y de rendimiento vehicular para determinar si los sujetos experimentaron de manera interna y externa dos niveles de carga cognitiva.
- Se desarrolló un índice que calcula e identifica los estados de baja y alta carga cognitiva basado en la información de las señales EEG.
- Se propone un nuevo método para el reconocimiento de patrones basado en la selección de características que combina pruebas estadísticas, algoritmos genéticos y regresión logística
  - Se desarrolló una técnica basada en algoritmos genéticos y regresión logística que consiste principalmente en seleccionar y evaluar la información EEG para identificar las características claves que contribuyan al reconocimiento de dos estados cognitivos.

- Se desarrolló una técnica para estructurar la información seleccionada basada principalmente en el manejo de grandes volúmenes de datos enfocada en la calidad y en la coherencia de los datos.
- Se desarrolló un modelo de predicciones para detectar los estados de baja y alta carga cognitiva de los sujetos al enfrentarse a escenarios de la conducción de un vehículo. El modelo implementa el índice desarrollado, las características seleccionadas y algoritmos supervisados.
- Se desarrolló una metodología de análisis de validación del modelo utilizando nuevas bases de datos para evaluar la capacidad de adaptación, conservando una alta tasa de predicción.
- Se desarrolló una metodología para evaluar el desempeño del modelo desarrollado con el objetivo de analizar sus alcances y limitaciones encontrando el ajuste óptimo de configuración para GALoRSI-SVMRBF.

## 5. RESULTADOS OBTENIDOS DE LA TESIS

### 5.1. Lista de Publicaciones

A continuación, se presenta una lista de publicaciones realizadas en base a este trabajo.

1. **Becerra, E.;** Reyes, A; Guerrero, A. Emotion Recognition Model based on Genetic Algorithms, Logistic Regression and Vector Support Machines using EEG Signals. **En preparación.**
2. **Becerra, E.;** Reyes, A; Guerrero, A. Feature Selection Model based on EEG signals to Assess the Cognitive Workload in Drivers. *Sensors* 2020, 20, 5881; DOI:10.3390/s20205881 (ISSN 1424-8220, Q1).
3. **Becerra, E.;** Reyes, A; Guerrero, A. Wearable Sensors for Evaluating Driver Drowsiness and High Stress. *IEEE Latin America Transactions*, 2019, vol. 17, no 03, p. 418-425. DOI: 10.1109/TLA.2019.8863312 (ISSN 1548-0992, Q4).

### 5.2. Colaboración

Durante el desarrollo de esta tesis, se realizó una colaboración con el Prof. Dr. Mario Miguel Ojeda Ramírez y la alumna de grado Ruth Elizabeth Aldama Rosas ambos de la Universidad de Veracruz, México, en el año 2017.

La investigación de esta colaboración se basó principalmente en el análisis y la evaluación de la información extraída de las señales EEG utilizando diversas técnicas estadísticas.

### 5.3. Seminario

**Becerra, E.**, “Hello world in TensorFlow”, Grupo de investigación ICARUS. Escuela de Ingeniería Eléctrica y Aeroespacial de Castelldefels de la Universidad Politécnica de Cataluña. Barcelona, España. 03, del 2017.

### 5.4. Reporte

Se desarrolló un manual de usuario para instalar y utilizar los sistemas BCI para la recolección y extracción de las señales EEG utilizando el sensor Emotiv EPOC y la herramienta LabView.

## 6. ESTRUCTURA DEL DOCUMENTO

Este documento está dividido en seis capítulos.

**Capítulo II** presenta el estado del arte que da soporte a los conceptos relacionados a este trabajo de investigación.

**Capítulo III** presenta la fase de recolección y procesamiento de los datos EEG para extraer la información que se utilizó para el desarrollo del modelo de predicciones. La información de este capítulo fue publicada en el artículo titulado “Wearable Sensors for Evaluating Driver Drowsiness and High Stress”

**Capítulo IV** presenta el desarrollo de una técnica de selección de características EEG y el desarrollo del modelo de predicciones para identificar y predecir los estados de baja y alta carga cognitiva. La información de este capítulo fue publicada en el artículo titulado “Feature Selection Model based on EEG signals to Assess the Cognitive Workload in Drivers”

**Capítulo V** presenta la fase de validación del modelo de predicciones implementado una base de datos internacional de señales EEG para analizar la capacidad de adaptabilidad del modelo a nuevos conjuntos de datos. La información de este capítulo fue utilizada para preparar el artículo titulado “A cognitive workload prediction model based on EEG signals during vehicle driving”.

**Capítulo VI** presenta un análisis del desempeño del modelo desarrollado evaluando diversas métricas para conocer los alcances, limitaciones y la mejor configuración del modelo. Parte de la información de este capítulo fue utilizada como soporte para preparar el artículo titulado “A cognitive workload prediction model based on EEG signals during vehicle driving”.

**Capítulo VII** presenta las conclusiones generales y trabajos futuros de esta tesis.



## CAPÍTULO II

### ANTECEDENTES

En este capítulo se presentan los conceptos y antecedentes que dan soporte al desarrollo de esta investigación el cual está dividido en dos partes. Primero, se introducen la carga cognitiva y conceptos relacionados, tales como, técnicas y herramientas utilizadas para medir y evaluar la carga cognitiva. Segundo, se introduce el concepto de aprendizaje automático, las fases de desarrollo de un modelo de aprendizaje automático y los principales algoritmos utilizados.

#### 1. CARGA COGNITIVA

La carga cognitiva es definida como la capacidad de demanda mental que requiere una persona para satisfacer una tarea en particular [18]. Cuando ejercemos tareas que exceden el nivel del esfuerzo mental, tendemos a sufrir retrasos en la capacidad de procesar la información, dejando de responder ante una situación y aumentando la posibilidad de cometer errores. Por ejemplo, en casos extremos con altos niveles de carga cognitiva, los sujetos podrían percibir un nivel elevado de estrés, debido a la gran cantidad de información que excede los recursos mentales disponibles. Por otro lado, cuando el nivel de carga cognitiva es excesivamente bajo, podría ocasionar fatiga en los sujetos, debido al decremento en los recursos mentales utilizados [19]. Cuanto mayor sea la cantidad de demanda mental requerida por el sujeto para realizar una actividad, mayor será la demanda de la carga cognitiva utilizada [20]. Por ello, es importante mantener un continuo monitoreo de la carga cognitiva requerida por los sujetos, al realizar tareas que demanden altos niveles de atención y concentración o al realizar tareas específicas y complejas para evitar una sobrecarga mental [21][22].

Una de las principales áreas donde se practica el continuo monitoreo de la carga cognitiva de los sujetos es en los sistemas que utilizan una interacción de tipo Máquina-Sujeto, ya que controlar el nivel del esfuerzo mental que requiere el sujeto al realizar una tarea específica podría ayudar a optimizar su desempeño y evitar errores en períodos prolongados de exceso de carga mental.

##### 1.1. Herramientas para Evaluar la Carga Cognitiva

Medir la carga cognitiva en los sujetos permite cuantificar el desgaste mental requerido al desempeñar una tarea específica. A medida que aumenta la dificultad de la tarea, disminuye el

rendimiento del sujeto y la cantidad de tareas completadas por unidad de tiempo. Esto provoca un incremento en el tiempo de respuesta y los errores cometidos [23].

La carga cognitiva no puede medirse directamente, por ello, se han desarrollado diversas herramientas que ayudan a medir la carga cognitiva dependiendo de la tarea que realice el sujeto. Estas herramientas se basan en la observación del comportamiento del sujeto utilizando tres principales enfoques como sugieren en [24]. Estos enfoques son: medidas subjetivas, medidas de rendimiento y medidas fisiológicas.

A continuación, se explican cada una de ellas.

### **1.1.1. Medidas Subjetivas**

Hasta la fecha las herramientas más utilizadas para medir la carga cognitiva de las personas son escalas obtenidas de las medidas subjetivas [25][26][27]. Estas medidas son caracterizadas por su fácil implementación basadas en cuestionarios que evalúan diversas dimensiones o aspectos tales como, demanda mental, física, temporal, desempeño, enfoque y frustración para obtener una escala cognitiva [28].

Estas medidas son utilizadas en un intento para capturar la interpretación de la carga cognitiva de una persona basada en su opinión o auto-evaluación durante y/o después de realizar la tarea a evaluar.

### **1.1.2. Medidas de Rendimiento**

La medida de rendimiento utilizada para analizar un sistema de tipo Máquina-Sujeto, está asociada con la capacidad que tiene el sujeto de mantener el sistema dentro de los márgenes de seguridad aceptables. Esta medida proporciona una correlación entre el desempeño total alcanzado por el sujeto al realizar una tarea y la carga cognitiva requerida para desempeñar la tarea [23].

El rendimiento puede evaluarse, clasificando la tarea en dos tipos: tarea primaria y tarea secundaria. La tarea primaria, evalúa el rendimiento del sujeto durante la tarea de interés y es considerada como referencia para conocer el estado base del sujeto. La tarea secundaria evalúa el desempeño del sujeto al realizar más actividades a partir de la tarea primaria [23].

Para evaluar la medida de rendimiento son utilizadas principalmente las siguientes métricas: tasa de error, velocidad, precisión, tiempos de reacción o respuesta.

### **1.1.3. Medidas Fisiológicas**

Las medidas fisiológicas proporcionan un monitoreo interno del sujeto en tiempo real, además, este tipo de medidas al ser no invasivas no interfieren con el desempeño del sujeto al realizar una tarea específica. Por lo tanto, las medidas fisiológicas pueden ser más útiles, precisas y adecuadas para evaluar la carga cognitiva de los sujetos [27].

En la actualidad, existen diversas señales fisiológicas utilizadas para evaluar la carga cognitiva de los sujetos. Las principales señales son EEG, ECG, EOG y EMG [29]. En particular, la

información EEG registra la actividad bioeléctrica cerebral de un sujeto, permitiendo que la señal sean más sensibles a los cambios de estados cognitivos y detectando con mayor precisión alertas de baja o alta carga cognitiva en comparación con otros indicadores fisiológicos [20][30][31].

La señal EEG registra la actividad cerebral que propagan las neuronas y son utilizados dos tipos de electrodos para recolectar la señal: electrodos invasivos y no invasivos. Los electrodos invasivos son colocados dentro de la superficie cerebral por medio de un procedimiento quirúrgico [32]. Los electrodos no invasivos son colocados sobre la corteza cerebral o cuero cabelludo donde el único requisito es que el electrodo entre en contacto con la superficie sin realizar ningún procedimiento quirúrgico [33]. Las señales EEG recolectadas por los electrodos invasivos o no se caracterizan por tener una amplitud de 10 a 100 micro voltios en una frecuencia de 1 a 100 Hz, las cuales se descomponen en cinco diferentes bandas de frecuencia como sugieren en [34] [35]. Estas bandas son: Delta (0.5–3 Hz), Theta (4–7 Hz), Alfa (8–12 Hz), Beta (13–30 Hz) y Gamma (30-100 Hz).

Las bandas de frecuencia se han empleado en diversas investigaciones como en [36][19][37] para evaluar estados cognitivos y emocionales de los sujetos al realizar diversas tareas. Cada banda está relacionada con un estado cognitivo como se observa en la Tabla 1. Por ejemplo, en [38][39] sugieren que la actividad de las bandas delta y theta están altamente relacionadas con la fatiga, cansancio o bajo rendimiento. En [22][40][41] se observó que la actividad de la banda alfa incrementó durante tareas de baja carga cognitiva. En [42] se observó un incremento en la actividad de la banda beta y gamma al realizar tareas con alta carga cognitiva. Por otro lado, existen otros estudios como en [38][43][44][45][46] que analizaron la relación entre las bandas de frecuencias y sus dependencias para evaluar diferentes comportamientos de las personas.

Tabla 1 Relación de las bandas de frecuencias con respecto a la actividad cerebral [47]

Brainwave Type	Frequency range	Mental states and conditions
Delta	0.1Hz to 3Hz	Deep, dreamless sleep, non-REM sleep, unconscious
Theta	4Hz to 7Hz	Intuitive, creative, recall, fantasy, imaginary, dream
Alpha	8Hz to 12Hz	Relaxed (but not drowsy) tranquil, conscious
Low Beta	12Hz to 15Hz	Formerly SMR, relaxed yet focused, integrated
Midrange Beta	16Hz to 20Hz	Thinking, aware of self & surroundings
High Beta	21Hz to 30Hz	Alertness, agitation

## 2. APRENDIZAJE AUTOMÁTICO

El aprendizaje automático (AA) es una rama de la Inteligencia Artificial, la estadística y la informática cuyo objetivo es estudiar y desarrollar modelos complejos, capaces de realizar predicciones exactas basándose en el comportamiento y la experiencia de los datos [48][49].

## **2.1. Fases para el Desarrollo de un Modelo de Aprendizaje Automático**

El proceso de desarrollo de un modelo de predicciones basado en AA se basa principalmente en cinco fases [50]. A continuación, se explica cada una de ellas.

### **2.1.1. Preprocesamiento de los Datos**

Uno de los principales desafíos a los que se enfrenta AA se encuentra en la información y su estructura. En específico, los problemas se presentan durante el proceso de recolección, debido a que los datos pueden variar en cantidad, formato e incluso contenido.

El preprocesamiento de los datos consiste principalmente en limpiar, filtrar, integrar, transformar e incluso reducir la información recolectada durante los experimentos, con el objetivo de obtener un conjunto de datos que sea de calidad y útil para las siguientes fases del modelo [51].

### **2.1.2. Selección de Características**

Las técnicas de selección de características permiten seleccionar de miles de datos generados, la información que mejor describa un evento o que sea capaz de resolver un problema. Estas características son definidas como identificadores para el reconocimiento de patrones y son implementadas como entradas de datos con el objetivo de optimizar el proceso de aprendizaje de los modelos de predicciones.

Existen diversas técnicas de selección de características como se proponen en [52] donde el algoritmo más destacado por su alta capacidad de analizar grandes cantidades de datos en espacios de búsqueda complejos o poco conocidos son los algoritmos genéticos (AGs).

Los AGs estructuran los datos de entrada en forma de un cromosoma donde cada elemento del cromosoma es un valor binario donde si el elemento tiene el valor de "1" indicará que es un dato seleccionado para continuar el proceso evolutivo y encontrar la solución del problema [53].

Los AGs a pesar de obtener una alta tasa de precisión al identificar las características relevantes, aún quedan varios aspectos que se pueden mejorar, como su complejo sistema evolutivo para encontrar el conjunto de datos adecuados y resolver el problema analizado.

### **2.1.3. Selección del Algoritmo**

La selección de un algoritmo de AA apropiado es fundamental para construir un modelo con una alta tasa de precisión en la clasificación de la información. La selección del algoritmo y la configuración de sus parámetros dependerá de varios factores, entre ellos, el tipo de datos de entrada y el problema que se desea resolver.

### **2.1.4. Entrenamiento del Modelo**

El entrenamiento es la fase donde el modelo aprende el comportamiento de los datos y es capaz de realizar predicciones de nuevos conjuntos de datos de entrada basado en su experiencia.



Esta fase depende principalmente del conjunto de datos de entrada, el algoritmo y el uso de los recursos computacionales para realizar un buen entrenamiento del modelo.

### 2.1.5. Validación

La fase de validación consiste en analizar el desempeño y los resultados obtenidos del modelo. Existen dos técnicas de validación: interna y externa. La validación interna consiste en aplicar las métricas de rendimiento, tales como, tasa de precisión, sensibilidad y exactitud enfocadas principalmente para analizar el desempeño del modelo. La validación externa se basa en emplear una nueva base de datos externa en el modelo con el objetivo de analizar y comparar los resultados del modelo [54].

## 3. ENFOQUES DE APRENDIZAJE AUTOMÁTICO

Dentro del AA existen principalmente dos tipos de algoritmos que son implementados en función a los datos que se tienen y el problema que se quiere resolver. Estos algoritmos se clasifican como supervisado y no supervisado [55].

### 3.1. Algoritmos Supervisados

Los algoritmos supervisados consisten en predecir el valor de un atributo a partir de un conjunto de datos de entrada que contienen una etiqueta que es la respuesta que el algoritmo deberá de producir. Su principal función es relacionar información con etiquetas para entender el comportamiento de los datos y realizar predicciones de nuevos conjuntos de datos.

En general, los algoritmos supervisados predicen la etiqueta  $y^*$  de una entrada desconocida  $x^*$  basada en su experiencia obtenida del conjunto de datos de entrada  $X$  y sus etiquetas  $Y$ ,  $(x^*, y^*) \in X * Y$  donde los datos de entrada  $X$  son vectores de características definidas como atributos donde la información que genera un sensor puede ser empleada como una dato de entrada en los modelos predictivos [56]. La etiqueta  $Y$  es el valor de los datos que permite categorizar la información conforme a las actividades realizadas durante los experimentos. La principal técnica de etiquetado es el mecanismo de ordenación binaria donde  $label \{xi, yi\} \in [0,1]$  es la etiqueta de los datos [43][57][58].

Existen diversos algoritmos de aprendizaje supervisado, en esta tesis nos centramos en la investigación de la implementación de los algoritmos k-NN (k-nearest neighbors), regresión lineal (RL- Regression Linear) y máquina de soporte vectorial (SVM- Support Vector Machine) caracterizados por ser rápidos, eficientes y poderosos al analizar y clasificar la información de las medidas fisiológica [43][59][60][61].

A continuación, se explica el funcionamiento de cada uno de estos algoritmos.

- I. k-NN: clasifica un nuevo conjunto de datos basado en la similitud de las observaciones en los datos de entrenamiento. El método consiste en comparar la nueva instancia  $x_0$  a clasificar con los datos  $k$  más cercanos conocidos, dependiendo del parecido entre los atributos para determinar las etiquetas  $y_0 \{x_0, y_0\}$  de la nueva instancia  $x_0$ . Este algoritmo utiliza la técnica de la distancia Euclidiana principalmente como una métrica para intentar encontrar el  $k$ -vecino más cercano. El valor  $k$  debe ser el apropiado, si el valor es grande la clasificación será generalizada, por el contrario si el valor es pequeño pocos datos serán seleccionados para realizar la comparación obteniendo una clasificación imprecisa [62].
- II. Regresión lineal: Esta técnica modela la relación del grado de dependencia de una característica independiente ( $x$ ) y el valor respuesta correspondiente de una característica dependiente ( $y$ ). Esta relación se realiza estableciendo una línea arbitraria que permite trazar una recta entre dos puntos donde la línea es calculada midiendo la distancia entre los puntos correspondientes a los valores  $(x,y)$  a partir de la Ecuación 1

$$Y = a_0 + bx$$

Ecuación 1

donde  $Y$  es la salida en forma de una función lineal,  $a_0$  es la intersección entre la línea y los datos,  $b$  es el coeficiente asociado con la variable de entrada y  $x$  son los parámetros de entrada [63].

- III. Máquinas de Soporte Vectorial: Es un método de clasificación binaria que mapea las muestras de entrada en un espacio de características de una dimensión base a una dimensión mayor para encontrar un hiperplano óptimo de separación de datos utilizando unos márgenes de separación para maximizar la distancia entre los datos y distinguir entre categorías como se observa en la Figura 1.




Figura 1 Hiperplano bidimensional del algoritmo SVM [64]

Los datos más próximos a los márgenes son denominados vectores de soporte y ayudan a construir el mejor hiperplano [64]. La función de decisión de SVM es descrita por la Ecuación 2

$$Y(x) = \text{sgn}(W \cdot X + b) = \text{sgn}\left(\sum_{i=1}^N a_i \cdot k * (X, X_i)\right) + b$$

Ecuación 2

donde  $W$  define el hiperplano de separación óptimo,  $b$  es el sesgo y  $\text{sgn}$  denota el signo de la función. SVM encuentra el valor óptimo que corresponde al hiperplano utilizando multiplicadores de Lagrange donde la función objetivo es minimizada con respecto a  $w$  y  $b$ :

$$L_p(x, b, a) = \frac{1}{1} \|w\|^2 - \sum_{i=1}^n a_i (y_i (x_i * w + b) - 1)$$

Ecuación 3

donde la solución de la Ecuación 3 se plantea de la siguiente forma:

$$L_p = \sum_i a_i - \frac{1}{2} \sum_{i,j} a_i a_j y_i y_j x_i * x_j$$

sujeito a  $0 \leq a_i \leq C$

Ecuación 4

donde  $a_i$  son los vectores de entrenamiento y  $C$  o penalty es el parámetro de regularización que controla el balance entre el máximo margen y la penalidad de la clasificación.

SVM puede ser utilizado en problemas de separación lineal y no lineal aplicando la función de kernel. La función kernel transforma los vectores de entrada  $x \in R^n$  dentro del vector  $\Phi(x)$  a un espacio de características de alta dimensión  $F$  (donde  $\Phi$  representa el mapeo:  $R^n \rightarrow R^f$ ) resolviendo el problema de clasificación lineal en el espacio de características [38]. Entre los kernels más comunes se encuentran:

$$k(x_i, x_j) = x_i^t \cdot x_j$$

Ecuación 5

$$k(x_i, x_j) = \exp(-\gamma \|x_i \cdot x_j\|^2)$$

Ecuación 6

donde la Ecuación 5 y la Ecuación 6 describen los kernels lineal y de base radial (RBF) con el parámetro  $\gamma$  y  $C$  que define la función gaussiana. Según el tipo de kernel y los valores de los parámetros se pueden obtener distintos hiperplanos de separación, para este estudio se han implementado ambos tipos de kernels.

### 3.2. Algoritmos no Supervisados

Cuando se desconoce el valor de la etiqueta en el conjunto de datos de entrenamiento, no se tiene el potencial necesario para realizar una solución predictiva supervisada. En estos casos son implementados algoritmos que descubren tendencias en los datos denominados no supervisados.

En estos algoritmos los datos de entrada  $x^*$  no han sido categorizados previamente y los algoritmos tendrán la tarea de encontrar patrones o comportamiento en los datos que permitan clasificar la información. La salida del modelo dependerá de la codificación del algoritmo dado que se desconoce cuáles deberían ser los resultados [50].

Con los algoritmos no supervisados no hay forma de determinar qué tan preciso es el modelo desarrollado y aunque dependiendo del problema será el tipo de algoritmo que se utilizará, cuando se habla de aplicaciones relacionadas con el análisis del comportamiento y salud de las personas son frecuentemente utilizados los algoritmos de aprendizaje automático supervisado.

## 4. CONCLUSIONES

Realizar un monitoreo del nivel de carga cognitiva de una persona al desempeñar una tarea específica es un factor clave en términos de seguridad donde un desbalance en el nivel de carga cognitiva puede ocasionar extremo cansancio o estrés influyendo en el rendimiento de las personas y alterando su capacidad de evaluación provocando accidentes al mínimo descuido.

En este capítulo, se presentaron las tres medidas más utilizadas para analizar la carga cognitiva de las personas al realizar diversas actividades. Estas medidas se han implementado por separado en diversos estudios para crear modelos que permitan analizar el comportamiento de las personas, como en [8][9] se enfocaron en implementar medidas subjetivas, en [65] utilizaron la medida de rendimiento de tasa de error y en [66] implementaron la señal fisiológica EEG.

En este sentido, pocas investigaciones han implementado en sus modelos la combinación de dos o más medidas con éxito debido a su alta complejidad al unir los diferentes tipos de datos para su análisis. Además, pocas son las investigaciones que han implementado algoritmos sofisticados y potentes como son los algoritmos de aprendizaje automático para analizar grandes volúmenes de datos complejos permitiendo obtener resultados con más precisión.

Al conocer las diversas medidas utilizadas para analizar el comportamiento de las personas y los algoritmos sofisticados capaces de soportar el modelo de los datos de estas medidas, nos

permite proponer nuevas técnicas para construir modelos de predicciones más eficientes con el objetivo de prevenir accidentes durante la conducción de un vehículo.



## CAPÍTULO III

### **PRIMERA FASE DEL DESARROLLO DEL MODELO DE PREDICCIONES: RECOLECCIÓN Y EXTRACCIÓN DE LA INFORMACIÓN PARA EL MODELO DE PREDICCIONES**

En este capítulo, se presenta el modelado de la extracción de la información de las señales EEG para identificar los niveles de baja y alta carga cognitiva de los sujetos durante la conducción de un vehículo. Estos identificadores son implementados en el modelo, para entrenar un clasificador y obtener una predicción del estado cognitivo del conductor.

Primero, se presenta el proceso de recolección y extracción de la información EEG. Después, se describe el desarrollo del clasificador utilizando el algoritmo denominado Máquinas de Soporte Vectorial (SVM - Support Vector Machine) comúnmente implementado para analizar datos de señales continuas. Por último, se presenta la evaluación del desempeño del clasificador propuesto para el modelo de predicción.

Los resultados fueron comparados con dos algoritmos de aprendizaje automático: k-vecinos más cercanos (k-NN – Nearest-Neighbors) y Regresión lineal (LR- Linear Regression). Estos algoritmos son caracterizados por ser potentes, eficientes y rápidos al analizar datos de series de tiempo como las señales EEG [59][60].

La información de este capítulo fue publicada en el artículo Becerra-Sánchez, E. P., Reyes-Muñoz, A., & Guerrero-Ibáñez, J. A. (2019). Wearable sensors for evaluating driver drowsiness and high stress. *IEEE Latin America Transactions*, 17(03), 418-425.

#### **1. INTRODUCCIÓN**

El desarrollo de las tecnologías para el monitoreo de actividades en diversas áreas, permite facilitar aspectos, tales como medir la cantidad de demanda mental que requiere un sujeto al realizar una tarea [67]. La demanda mental es conocida como carga cognitiva y su monitoreo es fundamental para evitar sobrecargas mentales en los sujetos al realizar actividades complejas, con un alto nivel de atención y concentración como la conducción de un vehículo [21][22].

Hasta la fecha, las herramientas más utilizadas para medir la carga cognitiva de las personas son escalas obtenidas de las medidas subjetivas como se muestra en [68][69], sin embargo, se

demostró en [18] que estas medidas tienen limitaciones, por ejemplo, los auto-reportes son inadecuados para el monitoreo continuo de la carga cognitiva, además, las respuestas pueden estar sujetas a prejuicios.

Estas limitaciones pueden ser reemplazadas utilizando medidas objetivas como los índices fisiológicos: señales EEG, ritmo cardíaco (HR), electrooculograma (EOG), entre otros.

En particular, las señales EEG capturan la actividad eléctrica cerebral en tiempo real. Esto permite que las señales sean sensibles a los cambios de estados cognitivos detectando alertas de estrés o relajación con más precisión en comparación con otros indicadores fisiológicos [31][30].

En los últimos años se han desarrollado modelos para identificar y predecir niveles de carga cognitiva en los sujetos utilizando señales EEG, con el objetivo de prevenir accidentes provocados por el exceso de demanda mental en situaciones exigentes ya que, a mayor dificultad en la tarea, mayor será la carga cognitiva utilizada para satisfacer la demanda de la tarea. Por ejemplo, en [14] proponen un modelo basado en la entropía de la información utilizando las señales EEG. El modelo presentó un 57% de precisión en la predicción al combinar la información del movimiento ocular, NASA-TLX y las señales EEG en comparación con un 90% al implementar la información de una sola fuente. En [15] proponen un modelo basado en técnicas estadísticas para predecir la carga cognitiva de los sujetos. Las señales EEG no identificaron eficientemente los cambios de estados cognitivos debido al exceso del esfuerzo mental requerido durante el experimento. Por último, en [16] diseñaron un modelo basado en el análisis de la discriminación lineal. La información de la señal EEG y la combinación de EEG+fNIRS (functional near-infrared spectroscopy) no mejoraron significativamente la clasificación de la carga cognitiva. El desarrollo de estos modelos puede llegar a ser costoso y complejo debido a la gran cantidad de datos que generan las señales EEG.

Las técnicas de Aprendizaje Automático (AA), son capaces de construir modelos para analizar miles de datos de forma rápida y dar soluciones a problemas como series de tiempo. En este sentido, muchos grupos de investigación han trabajado en el tema de la evaluación y predicción de la carga cognitiva, utilizando algoritmos de AA con información de índices fisiológicos (tales como, EEG, EMG, EOG y ritmo cardíaco), como en [56][70] los autores proponen un modelo de reconocimiento de emociones basado en las señales EEG. Estos modelos logran mejorar sólo un 10% el rendimiento del clasificador utilizando la información de una o varias bandas el cual no demuestra una diferencia estadísticamente significativa, además, la recolección de las señales EEG no es realizada en tiempo real. En [22] los autores presentan un modelo para evaluar la carga cognitiva basado en red neuronal artificial utilizando las señales EEG para identificar diferentes niveles de la carga cognitiva. En esta investigación, la configuración de parámetros del modelo fue sensible a los datos provocando un sobre entrenamiento en la red neuronal. En [71] identifican el estado de somnolencia utilizando varios métodos basados en el análisis multi-dominio para extraer características de las señales EEG. En esta investigación utilizan algoritmos genéticos básico para la selección de los parámetros, incrementando el tiempo de entrenamiento



del modelo. En [72] se presenta un sistema para evaluar los niveles de alerta de una persona durante la conducción de un vehículo. En esta investigación utilizan algoritmos computacionalmente complejos para analizar las señales EEG. En [73][74] los autores emplearon redes de creencia profunda y redes de aprendizaje profundo para desarrollar modelos de detección de estados emocionales basado en las señales EEG. En ambos estudios, el tiempo computacional requerido para entrenar las redes neuronales es alto, provocando conflicto en el flujo de datos secuenciales.

En este capítulo, se presenta el modelado de la extracción de la información de las señales EEG para identificar los niveles de baja y alta carga cognitiva relacionada con la relajación y el estrés durante la conducción como se observó en [22][75]. Estos identificadores son implementados en el modelo, para entrenar un clasificador y obtener una predicción del estado cognitivo del conductor.

Primero, se presenta el desarrollo de una interfaz que recolecta y procesa la información de las señales EEG. Después, para analizar los miles de datos generados de las señales EEG, se diseñó una metodología de agrupación de la información permitiendo organizar y filtrar la información relevante, reduciendo la dimensionalidad del conjunto de datos, con el objetivo de buscar las características que mejor describan a cada estado cognitivo. Esta metodología optimizó el proceso de entrenamiento y predicción del modelo.

Por último, se presenta el clasificador desarrollado utilizando el algoritmo de Máquinas de Soporte Vectorial (SVM - Support Vector Machine) comúnmente implementado para analizar datos de señales continuas. Para evaluar el desempeño del clasificador propuesto, los resultados fueron comparados con dos algoritmos AA caracterizador por su potencia y rapidez al examinar y clasificar los datos, resolviendo problemas de clasificación binaria: k-vecinos más cercanos (k-NN - Nearest-Neighbors) y Regresión lineal (LR- Linear Regression).

## 2. METODOLOGÍA

En esta sección se describe el desarrollo del modelado de la información EEG. El método consiste en monitorear el comportamiento de un conductor de vehículo, recolectando y registrando periódicamente las señales EEG por medio de la diadema Emotiv EPOC, mientras se enfrenta a un escenario de conducción. La información recolectada fue analizada, calculando la Densidad Espectral de Potencia (PSD -Power Spectral Density) para extraer las características espectrales y utilizar la información como entradas de datos en el modelo de predicciones.

Para manipular la información extraída de PSD se desarrolló un método de agrupación de datos. Este método permite reestructurar los datos para identificar las características más relevantes de cada estado, sin perder información o generalizar los valores extraídos. Estas características fueron implementadas como identificadores de baja y alta carga cognitiva en tres clasificadores utilizando los algoritmos SVM, k-NN y LR.

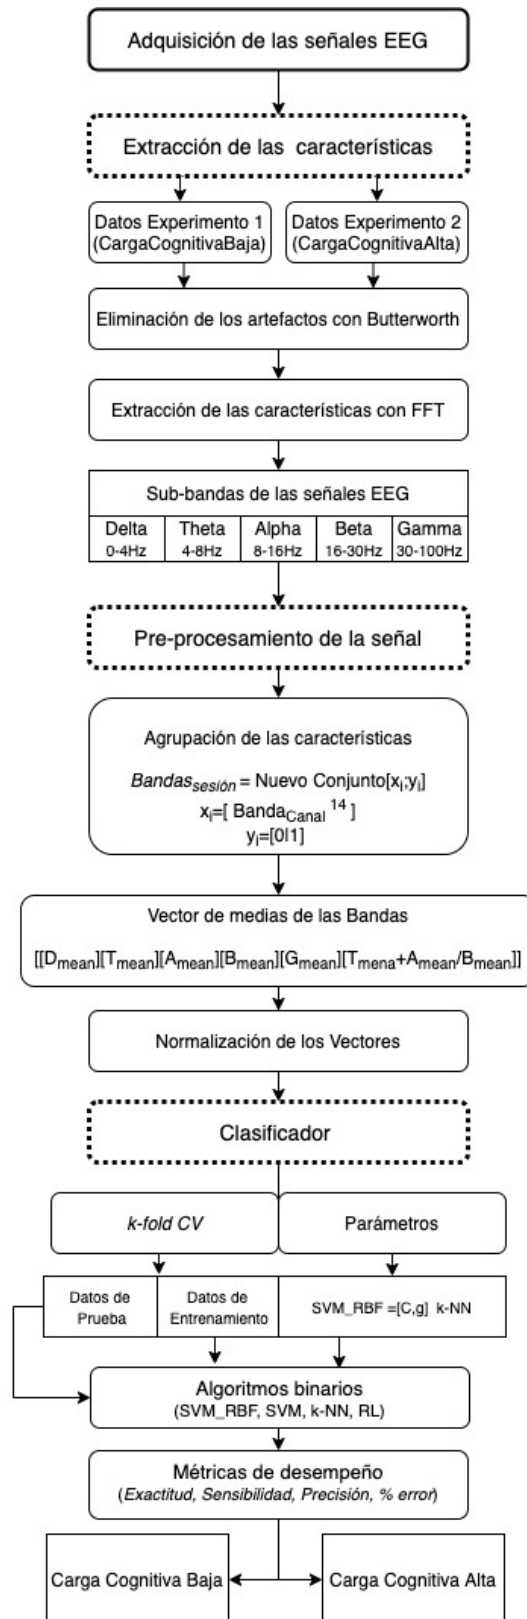


Figura 2 Diagrama del modelo para detectar altos o bajos niveles de carga cognitiva del conductor

En esta investigación, los algoritmos de AA se desarrollaron en dos fases. La primera fase es el entrenamiento y prueba del modelo, donde se construye el modelo a partir de un conjunto de datos de entrada con una etiqueta de la categoría a la que pertenecen. Además, en esta fase los parámetros del modelo son ajustados.

La segunda fase es de validación y consiste en evaluar el modelo desarrollado con un nuevo conjunto de datos que no fueron utilizados en la fase de entrenamiento.

En la Figura 2 se muestra la arquitectura general del modelo propuesto. El modelo está conformado por cuatro módulos: adquisición de los datos, extracción de características, preprocesamiento y procesamiento de los datos. A continuación, se explica a detalle cada uno de los módulos definidos en esta arquitectura.

## 2.1. Adquisición de los Datos

Existe una gran variedad de sensores no invasivos utilizados en diversas investigaciones para la recolección de las señales EEG. Para este trabajo, se utilizó el sensor EMOTIV EPOC [76] de 14 canales (AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 y AF4) distribuidos acorde al sistema internacional 10-20 [77], con una frecuencia de muestreo de 128 Hz y una resolución de 14 bits [42]. Los datos de las señales EEG son enviados al ordenador de forma inalámbrica utilizando la tecnología *Bluetooth* y almacenados en un archivo de extensión \*.edf. Se desarrolló una interfaz de usuario utilizando librerías y herramientas de LabVIEW para comunicar y procesar los datos recolectados del sensor, como se observa en el Anexo A.

Esta interfaz permite visualizar la señal en tiempo real y grabar la información por segundo. Como se observa en la Figura 3 la información de cada canal es almacenada en un archivo de extensión \*.csv utilizando la unidad de medida de microvoltio.

F	G	H	I	J	K	L	M	N	O
ED_F3	ED_FC5	ED_T7	ED_P7	ED_O1	ED_O2	ED_P8	ED_T8	ED_FC6	ED_F4
4219	4144	3986	4304	4288	4446	4545	4166	4405	4192
4208	4131	3984	4291	4285	4430	4519	4166	4376	4176
4208	4130	3982	4294	4283	4430	4515	4166	4375	4164
4189	4124	3982	4289	4278	4410	4490	4164	4345	4143
4185	4125	3986	4290	4281	4411	4493	4165	4345	4150
4207	4130	3985	4291	4279	4433	4527	4167	4386	4182
4207	4127	3983	4286	4274	4435	4527	4167	4389	4182
4184	4119	3984	4282	4276	4418	4501	4165	4356	4156
4170	4113	3985	4279	4273	4410	4491	4166	4345	4151
4173	4111	3984	4274	4270	4412	4493	4167	4347	4156
4178	4111	3984	4271	4271	4406	4489	4167	4342	4156
4176	4107	3985	4269	4271	4408	4494	4166	4347	4162

Figura 3 Datos generados de las señales EEG

## 2.2. Extracción de Características

La extracción de características tiene como objetivo capturar la información fisiológica (denominada "característica") que está relacionada con la activación de los diferentes músculos del cuerpo [42]. El proceso de extracción de características consiste en transformar las señales

originales, en características que representan el comportamiento de las señales. En la literatura, se distinguen tres tipos de características de las señales EEG [21][78]. Estas características son: dominio del tiempo, dominio de la frecuencia y dominio del tiempo-frecuencia.

Las características del dominio de la frecuencia son las más populares en el contexto de la carga cognitiva como proponen en [34] ya que permiten extraer cinco bandas de frecuencia las cuales son: Delta (0.5–4 Hz), Theta (4–8 Hz), Alfa (8–12 Hz), Beta (12–30 Hz) y Gamma (30-100 Hz). En esta investigación fue utilizado PSD para analizar las señales EEG en el dominio de la frecuencia. PSD determina la distribución de la potencia de la señal a lo largo de un determinado rango de frecuencias, facilitando la extracción de las características espectrales de cada canal [35].

Las señales como tal, son sensibles a las actividades denominadas *artefactos* o movimientos corporales generados principalmente por el movimiento del parpadeo o la respiración durante el análisis de la actividad de las señales EEG, alterando su calidad y el deterioro de su registro [72]. Para eliminar los artefactos en las señales EEG, fue utilizado el filtro de tipo pasabanda con tipología Butterworth de orden 3 con una frecuencia de corte de 0,1Hz. como se propone en [56]. En comparación con otros filtros, Butterworth tiene una respuesta lineal permitiendo filtrar y descomponer las señales EEG [79].

Una vez realizado el filtrado de la señal, es calculada la Transformada Rápida de Fourier (FFT) con una ventana Hanning de 128 muestras a una longitud de  $T=5s$  para eliminar la discontinuidad de los datos y segmentar la información como se propone en [34]. FFT convierte la señal del dominio del tiempo al dominio de la frecuencia extrayendo la magnitud del espectro de potencia de las 5 bandas de frecuencia [80]. Estas características fueron calculadas para cada uno de los 14 canales del sensor.

Como se observa la Figura 4 el rango de potencia de la frecuencia de interés fue calculada como se presenta en la Ecuación 7.

$$RP_x(f_1, f_2) = \frac{p_x(f_1, f_2)}{p_x(f_{min}, f_{max})}$$

Ecuación 7

donde  $p_x(f_1, f_2)$  es la potencia dentro del rango de frecuencia que se desea extraer de la señal y  $p_x(f_{min}, f_{max})$  es la potencia en todo el rango de frecuencia  $[f_{min}, f_{max}]$  de la misma señal.




Figura 4 Panel frontal de la recolección de las señales EEG

En Figura 4 se presenta el panel frontal de visualización de la interfaz desarrollada para la recolección de los datos, donde se puede observar la distribución de la frecuencia de la señal extraída de cada una de las bandas. También, se observa el valor de la magnitud del espectro de potencia de cada banda, el cual es almacenado en un archivo con extensión \*.csv para su posterior análisis. En la Figura 6 se muestra el diagrama de bloque de la interfaz diseñado para extraer las características espectrales de las bandas, donde una vez aplicada la FFT, la señal es filtrada conforme a la frecuencia de interés y el valor máximo de la frecuencia es almacenado [81][82].

En esta investigación, los datos fueron almacenados conforme a cada estímulo aplicado al sujeto. Un total de 300 características por sesión fueron extraídas y almacenadas.

### 2.3. Preprocesamiento

La implementación de la técnica de preprocesamiento de datos es importante en los modelos de predicción. El preprocesamiento consiste en seleccionar de miles de datos recolectados, la información que mejor describe un evento [83]. En esta investigación, se desarrolló un método de agrupación para seleccionar y reducir la dimensionalidad de los datos, con el objetivo de preparar las muestras como datos de entrada al modelo y facilitar el proceso de entrenamiento y aprendizaje del clasificador [84].

La técnica de preprocesamiento está formada por tres etapas. En la primera etapa la información extraída por canal es organizada por bandas de frecuencia como se observa en la Ecuación 8

$$Banda\_Fre = [[Ch_{AF3}][Ch_{F7}][Ch_{F3}][Ch_{FC5}][Ch_{T7}][Ch_{P7}][Ch_{O1}][Ch_{O2}][Ch_{P8}][Ch_{T8}][Ch_{FC6}][Ch_{F4}][Ch_{F8}][Ch_{AF4}]]$$

Ecuación 8

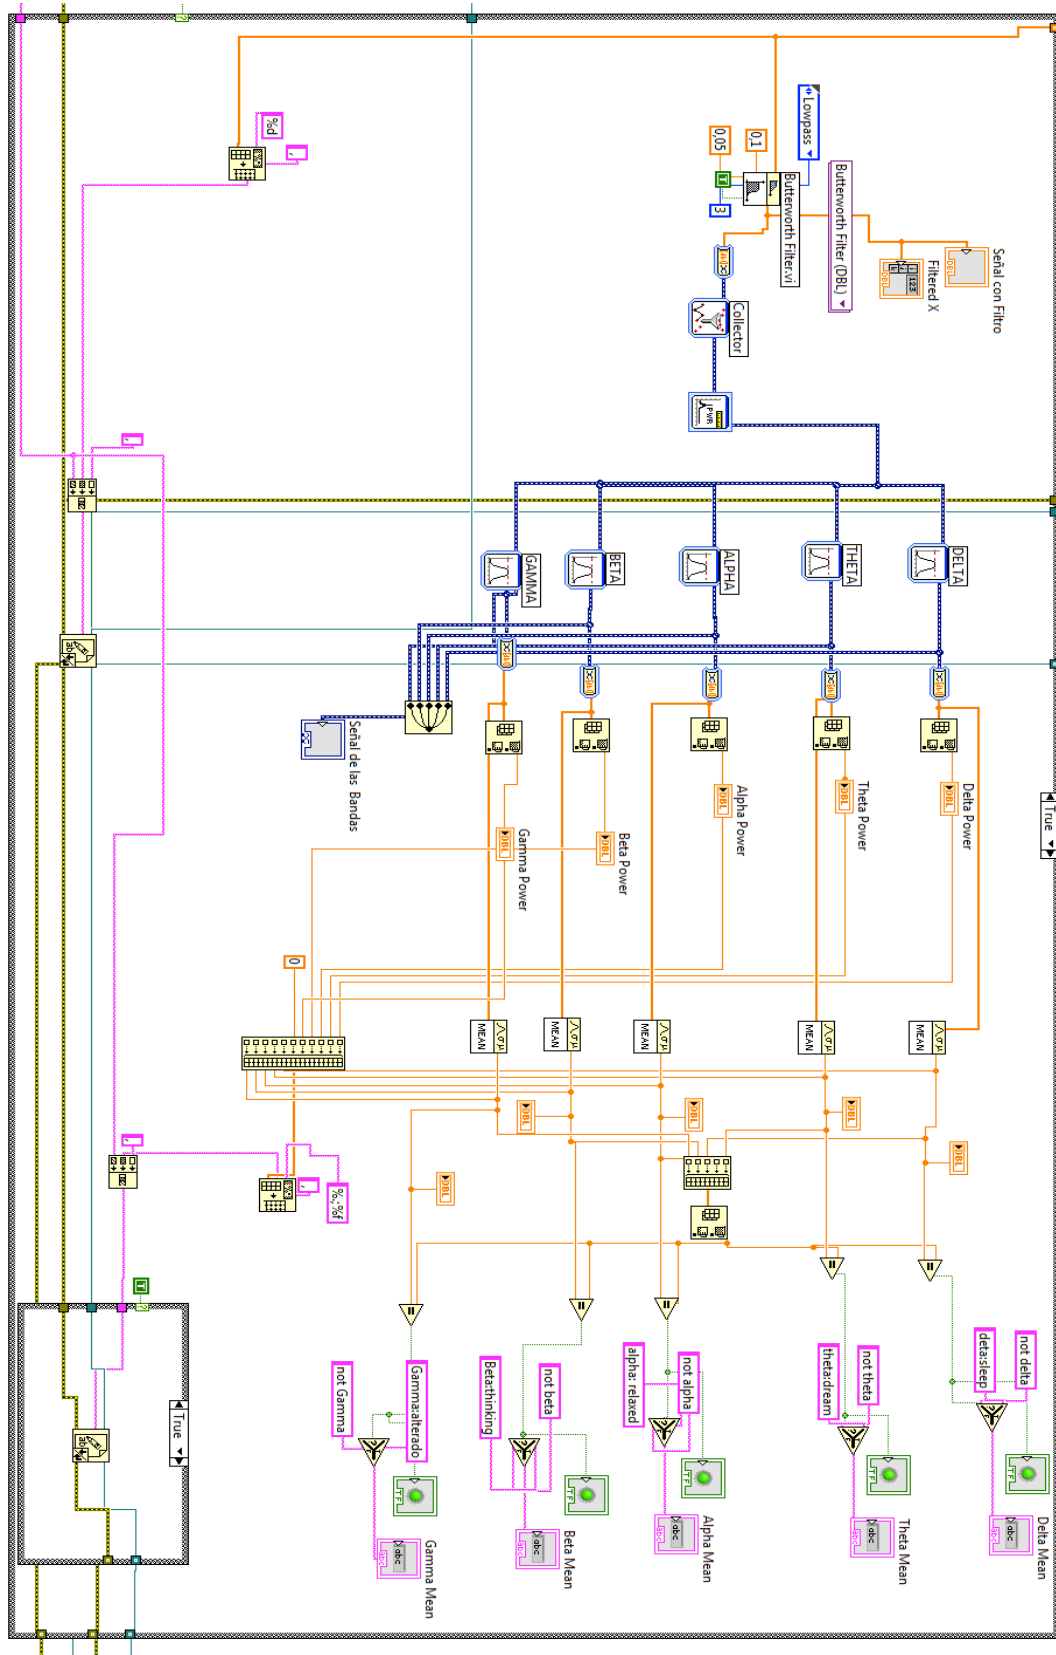


Figura 5 Diagrama de Bloques de la extracción de las cinco características espectrales de las señales EEG

donde  $Cb$  representa la información extraída de cada uno de los 14 canales y  $Banda\_Fre$  representa las bandas de frecuencia delta, theta, alfa, beta y gamma. La información de cada canal es agrupada en relación a cada matriz de banda de frecuencia como en [84], obteniendo cinco matriz con 14 características donde cada característica representa la información de canal como se observa en la **Error! Reference source not found.**

$$\begin{bmatrix} \begin{bmatrix} \alpha_{ch1} & \cdots & \alpha_{ch14} \\ \vdots & \ddots & \vdots \\ \alpha_{chN} & \cdots & \alpha_{chN} \end{bmatrix} \begin{bmatrix} \theta_{ch1} & \cdots & \theta_{ch14} \\ \vdots & \ddots & \vdots \\ \theta_{chN} & \cdots & \theta_{chN} \end{bmatrix} \begin{bmatrix} \delta_{ch1} & \cdots & \delta_{ch14} \\ \vdots & \ddots & \vdots \\ \delta_{chN} & \cdots & \delta_{chN} \end{bmatrix} \begin{bmatrix} \beta_{ch1} & \cdots & \beta_{ch14} \\ \vdots & \ddots & \vdots \\ \beta_{chN} & \cdots & \beta_{chN} \end{bmatrix} \begin{bmatrix} \gamma_{ch1} & \cdots & \gamma_{ch14} \\ \vdots & \ddots & \vdots \\ \gamma_{chN} & \cdots & \gamma_{chN} \end{bmatrix} \end{bmatrix}$$

Ecuación 9

En la segunda etapa, es calculada la media de cada fila de la matriz para obtener un vector de medias por cada banda de frecuencia como se observa en la **Error! Reference source not found.** Esta técnica permite organizar grandes volúmenes de datos.

$$\begin{bmatrix} \begin{bmatrix} \alpha_{mean} \\ \vdots \\ \alpha_{mean_N} \end{bmatrix} \begin{bmatrix} \theta_{mean} \\ \vdots \\ \theta_{mean_N} \end{bmatrix} \begin{bmatrix} \delta_{mean} \\ \vdots \\ \delta_{mean_N} \end{bmatrix} \begin{bmatrix} \beta_{mean} \\ \vdots \\ \beta_{mean_N} \end{bmatrix} \begin{bmatrix} \gamma_{mean} \\ \vdots \\ \gamma_{mean_N} \end{bmatrix} \end{bmatrix}$$

Ecuación 10

En la última etapa los datos de los vectores son normalizados en un rango de [-1, +1] como se propone en [74] para dar uniformidad y homogeneidad en los datos.

Para determinar la relación entre las señales EEG y los estados cognitivos, son utilizados los indicadores cognitivos basados en las bandas de frecuencia. En el contexto de la carga cognitiva, para medir la demanda mental requerida por el sujeto al realizar una tarea, son utilizadas las bandas de frecuencia como una técnica fiable para detectar diversos estados cognitivos en tiempo real [67]. Cada banda está relacionada con una actividad cerebral que es estimulada de acuerdo a la complejidad de la tarea que desempeña el sujeto [64]. Por ejemplo, el incremento de la actividad de las bandas theta o alfa es asociada al estado de fatiga, relajación o cansancio. El incremento de la actividad de las bandas beta o gamma es asociada al estado de estrés, alteración o sobrecarga del esfuerzo mental [22][31][38][47].

En [38][43][38][44][40][45] utilizaron los indicadores cognitivos y su dependencia entre ellos para identificar diversos estados cognitivos relacionados con el estrés y la relajación. En estas investigaciones implementaron diversos métodos y técnicas para agrupar la información relevante de cada identificador, sin considerar que pueden generalizar los valores de los datos recolectados provocando una incorrecta predicción del estado real en que se encuentra el sujeto.

En nuestra investigación fueron implementados los indicadores cognitivos calculados por el método de agrupación los cuales son:  $[\alpha_{mean}], [\theta_{mean}], [\delta_{mean}], [\gamma_{mean}], [\beta_{mean}]$ . Además, fue calculada e implementada la relación  $[(\theta_{mean} + \alpha_{mean} / \beta_{mean})]$  como un indicador para detectar estados de estrés. Un incremento en el valor de esta relación, es vinculado con un incremento del nivel de estrés [46]. En total seis indicadores cognitivos fueron implementados para entrenar nuestro modelo.

## 2.4. Procesamiento

El modelo de predicción de carga cognitiva basado en señales EEG fue desarrollado utilizando algoritmos de clasificación supervisada. Los algoritmos supervisados consiste en predecir una etiqueta  $y^*$  de una entrada desconocida  $x^*$  basado en un conjunto de etiquetas  $Y$  de datos de entrada conocidos  $(x, y) \in X * Y$  donde  $x$  es el conjunto de datos de entrenamiento que deberán ser etiquetados con un valor  $y$  [56]. En [43][57][58] utilizaron el mecanismo de ordenación binaria para etiquetar los datos de entrada. Este mecanismo, etiqueta la información utilizando las actividades de la experimentación como un categorizador de datos donde  $label \{x_i, y_i\} \in [0,1]$  [84].

En esta investigación fue implementado el mecanismo de ordenación binaria para etiquetar la información recolectada utilizando las fases del experimento para catalogar los datos. Los grupos se etiquetaron manualmente como  $y = [0, 1]$  donde 0 es relacionado al estado base o primera fase del experimento y 1 es relacionada al estado cognitivo alto o a la fase dos.

Para desarrollar el clasificador fueron utilizando los algoritmos kNN, LR y SVM por su alta efectividad al implementarlos [43]. Además, estos algoritmos son caracterizados por ser rápidos y poderosos al analizar y clasificar la información generada de las medidas fisiológicas [59][60][61]. A continuación, se explica el funcionamiento de cada uno de estos algoritmos.

- I. k-NN. Consiste en comparar la nueva instancia  $x_o$  a clasificar con los datos  $k$  más cercanos conocidos, dependiendo el parecido entre los atributos para determinar las  $N$  etiquetas  $\{x_i, y_i\}$  de la nueva instancia  $x_o$  [62].
- II. LR. Esta técnica modela el ajuste de la relación de dependencia entre una característica específica independiente ( $x$ ) y el valor respuesta correspondiente ( $y$ ). Esta relación se realiza estableciendo una línea arbitraria que permite trazar una recta entre dos puntos donde la línea es calculada midiendo la distancia entre los puntos correspondientes a los valores  $(x,y)$  a partir de la Ecuación 11

$$Y = a_0 + bx$$

Ecuación 11

donde  $Y$  es la salida en forma de una función lineal,  $a_0$  es la línea que intersecta los dos puntos,  $b$  es el coeficiente asociado con la variable de entrada y  $x$  son los parámetros de entrada.

- III. SVM. Es un método que mapea las muestras de entrada en puntos sobre un espacio de características para encontrar un hiperplano óptimo de separación. Utiliza márgenes de separación para maximizar la distancia entre los puntos más cercanos y distinguir entre clases. Los datos cercanos a los márgenes son denominados vectores de soporte y construyen el mejor hiperplano de separación [85]. La función de decisión de SVM es descrita por la Ecuación 12.



$$Y(x) = \text{sgn}(W \cdot X + b) = \text{sgn}\left(\sum_{i=1}^N a_i \cdot k * (X, X_i)\right) + b$$

*sujeito a*  $0 \leq a_i \leq C$

Ecuación 12

donde  $w$  define el hiperplano de separación óptimo,  $b$  es el sesgo,  $\text{sgn}$  denota el signo de la función y  $a_i$  son los vectores de soporte y  $C$  es el parámetro de regularización de los márgenes [86].

Todos los algoritmos fueron entrenados y validados con el mismo conjunto de datos, utilizando la estructura que a continuación se presenta

$$EEG\_data (sample, type, kernel, parameters) \rightarrow \{high, low\}$$

donde  $EEG\_data$  son los datos observados en un intervalo de tiempo,  $sample$  el vector de características y  $\{high, low\}$  es los conjuntos de datos al ser discriminados como cargas cognitivas altas o bajas.

### 3. EXPERIMENTOS

#### 3.1. Sujetos Experimentales

Para el proceso del experimento, los datos fueron tomados de 12 conductores que gozan de buena salud, con un rango de edad entre 21-30 años, con una media de 24.65 años y con carné de conducir con una vigencia mínima de 2 años. Los conductores evitaron el consumo de alcohol, cafeína o medicamentos que causan somnolencia por lo menos 24 horas antes de la prueba. Además de un consentimiento firmado en el que cada uno de los participantes aceptan la recolección de información y procesamiento de sus datos dentro de las condiciones del experimento.

#### 3.2. Procedimiento Experimental

A cada participante se le solicitó que condujera un vehículo dentro de una zona urbana a primera hora de la tarde por un tiempo aproximado de 50 minutos. El experimento se realizó en dos fases con una duración de 20 minutos cada fase y un descanso intermedio de 10 minutos. En la primera fase, el participante inicia a conducir sin música de fondo o cualquier tipo de distracción para incitar un bajo nivel de carga cognitiva. La segunda fase del experimento consiste en realizar una segunda tarea simultáneamente a la conducción donde al participante se le aplica el protocolo de inducción de estrés propuesto en [87] para estimular altos niveles de carga cognitiva. En cada fase del experimento el sensor EMOTIV EPOC [74] recolectó información de las señales EEG. Además, se le solicitó al participante

que completara dos auto-reportes para obtener la percepción de la carga cognitiva del propio participante. El primero se realiza durante el experimento siguiendo la auto-evaluación ISA [69] que se aplica cada 2 minutos y tiene una escala del 1 a 5 donde (1) es aburrido y (5) muy ocupado. También, se utilizó el post-exercise NASA-TLX [68] que calcula seis factores para evaluar la demanda subjetiva, su rango de escala va de 0 a 100 donde 100 es el esfuerzo máximo requerido para realizar una tarea.

## 4. CONFIGURACIONES

### 4.1. Métricas y Parámetros

Para evitar el sobreajuste de los datos al crear el modelo, fue utilizado k-fold cross-validation (k-fold CV) por su bajo costo computacional y sesgo al evaluar el rendimiento del modelo. k-fold CV cuenta con el parámetro  $k$  donde para encontrar su mejor configuración, fueron evaluados los datos con diferentes  $k=valores$  hasta encontrar el valor con el mejor desempeño del modelo. Para el conjunto de datos utilizados en este capítulo, fue realizado un nuevo análisis de ajuste entre la información y los parámetros donde la mejor configuración fue de  $k=5$ .

k-fold CV divide los datos de manera aleatoria en  $k-1$  subconjuntos. El 80% de los datos divididos son destinados para entrenar y evaluar el modelo donde el 70% de los datos son utilizados para entrenar el modelo evitando el desajuste y sobreajuste de los datos y el 10% de los datos es destinado para evaluar el modelo entrenado. El 20% de los datos restantes es reservado para validar el clasificador. El ajuste de configuración de los parámetros fue basado en los datos de entrada y la fase de entrenamiento del modelo.

El conjunto de datos de entrada construido para entrenar el modelo está conformado por una matriz de  $9*164$  donde 9 son los atributos y 164 presenta el número total de observaciones en el conjunto de datos. Es importante considerar que durante el experimento se recolectaron aproximadamente cuatro datos por minuto para su análisis. En la Figura 6 se presentan los datos del modelo.

Data_Id	Etiqueta	Theta	Gamma	Delta	Beta	Alpha	theta+alpha/	Sujetos
1	0	0.67502832	0.41578174	-0.25679	-0.606649	0.55717027	-0.2434109	1
2	0	0.70426798	0.41090003	-0.1564552	-0.5295148	0.5191294	-0.276119	1
3	0	0.71507871	0.4068825	-0.104782	-0.4512619	0.4616394	-0.3079179	1
4	0	0.69546604	0.40421718	-0.0267476	-0.3553282	0.42692676	-0.5060337	1
5	0	0.70095837	0.40721783	0.05268991	-0.2516043	0.35307857	-0.7023503	1
6	0	0.66911936	0.41760552	0.1459394	-0.1436739	0.28270039	-1.2985338	1
7	0	0.62946105	0.43067199	0.20694673	-0.0317162	0.22972162	-6.61357	1
8	0	0.58777413	0.44574198	0.24753496	0.08545097	0.17843371	2.6753597	1

Figura 6 Datos de entrada del modelo de predicción.

El atributo Data\_ID asigna un identificador a cada valor. El atributo etiqueta se utiliza para categorizar los datos recolectados conforme a cada fase del experimento, donde 0 es asignado para los datos de la fase uno y 1 para los datos recolectados en la fase dos. Los seis

indicadores cognitivos  $[\alpha_{\text{mean}}, [\theta_{\text{mean}}, [\delta_{\text{mean}}, [\gamma_{\text{mean}}, [\beta_{\text{mean}}]$  y  $[(\theta_{\text{mean}} + \alpha_{\text{mean}} / \beta_{\text{mean}})]$  son implementados como atributos para el reconocimiento y clasificación de patrones. Por último, el atributo *sjetos* identifica la información que fue recolectada por cada participante. Todos los datos utilizados en el modelo fueron normalizados para homogeneizar la información.

Para estimar el ajuste de los parámetros  $C$  y  $\gamma$ , utilizamos la técnica gridsearch con una configuración cross-validation ( $c-v$ ) para automatizar el ajuste de los parámetros [88]. Gridsearch  $c-v$  define un directorio con los parámetros para desempeñar múltiples combinaciones de valores a diferentes escalas utilizando el método de validación cruzada, encontrando los parámetros que brinden un mejor ajuste con respecto a los datos, optimizando el tiempo de entrenamiento y disminuyendo la tasa de error en la clasificación [89].

En esta investigación la configuración de los parámetros se realizó en base al método de secuencia de crecimiento exponencial utilizados en [90][91] donde los rangos fueron:  $C = \{1, 10, 100, 1000\}$  y  $\gamma = \{1e-2, 1e-3, 1e-4, 1e-5\}$ . Un total de 200 ajustes en paralelo fueron calculados, donde, a mayor valor de  $C$ , el modelo SVM establecerá un hiperplano de menor margen ajustándose mejor a los datos.

El modelo fue desarrollado utilizando la librería para AA Tensor Flow en Python 2.7.

## 5. RESULTADOS

Para analizar los resultados de los algoritmos SVM RBF, SVM lineal, k-NN y RL fue implementada la matriz de confusión como se presentan en la Figura 7. La matriz de confusión contiene la información sobre la clasificación real y pronosticada de cada algoritmo, calculando las métricas de: exactitud, sensibilidad, precisión, especificidad y tasa de error.

En la Tabla 2 se presentan los resultados de cada una de las métricas de los clasificadores. El algoritmo que obtuvo la mayor tasa de predicción al clasificar los datos fue SVM tipo RBF con un porcentaje de exactitud del 93.93%, es decir, casi el total de los datos de entrada fueron clasificados correctamente. Este resultado se obtuvo con la configuración de parámetros  $C=10$  y  $\gamma= 0.1$ . Por otro lado, SVM lineal obtuvo un 90.9% de exactitud en la clasificación de los datos. k-NN con una configuración de parámetro de  $k\text{-value}=2$ , obtuvo una tasa de exactitud en la clasificación de los datos del 84.84%. Por último, RL fue implementado con una configuración de parámetros predeterminados, logrando una tasa de exactitud del 54.54% en la clasificación de los datos.

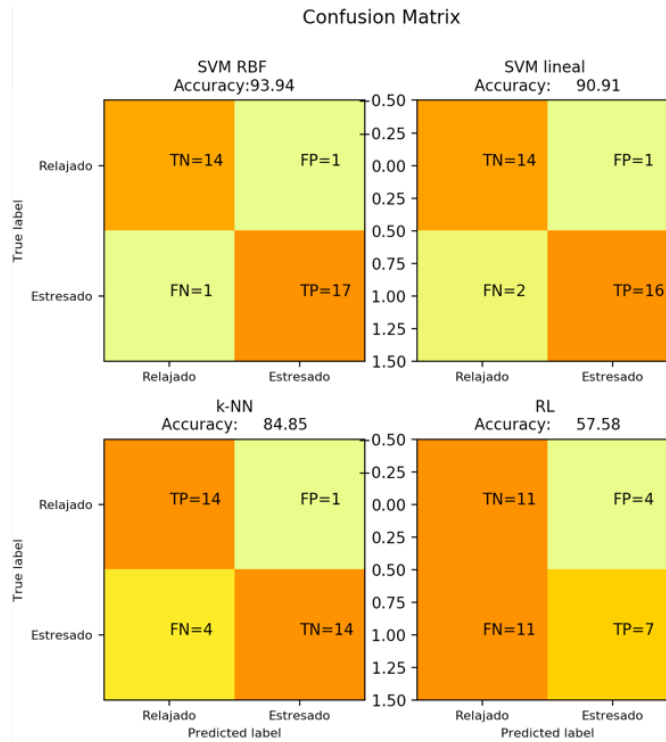


Figura 7 Matriz de confusión de los clasificadores SVM, RL y k-NN

También en la tabla se observa que SVM tipo RBF obtuvo un mayor porcentaje de sensibilidad y precisión al clasificar los datos con un 94.44% en ambas métricas, seguido de SVM lineal con un 88.88% y 94.11%, k-NN con un 77.77% y 93.33. Por último, RL con un 38.88% y 63.63% en la sensibilidad y precisión.

Tabla 2 Resultados del modelo de predicción

Resultados de las métricas de evaluación				
Clasificadores	Exactitud	Sensibilidad	Precisión	% Error
SVM_RBF	93.93%	94.44%	94.44%	6%
SVM LINEAL	90.90%	88.88%	94.11%	9.1%
k-NN	84.84%	77.77%	93.33	15.16%
RL	54.54%	38.88%	63.63	45.46%

Por otro lado, los resultados obtenidos al calcular la tasa de error durante la clasificación fueron, con el algoritmo RL se obtuvo la mayor tasa de error con un 45.46%, seguido de k-NN con un 15.16% de error, SVM lineal con un 9.1% y por último SVM RBF que obtuvo la menor tasa de error con un 6%.

Es importante considerar que los modelos de predicción deben de tener un margen mínimo de tasa de error en los resultados, en especial cuando se trata de datos de señales fisiológicas ya que representa la fiabilidad del clasificador.

## 6. DISCUSIÓN

En este capítulo, el objetivo fue presentar el desarrollo del modelado de la información EEG para construir un modelo de predicción basado en técnicas de AA.

En estudios previos como en [92][93][94] se presentan investigaciones relacionadas con modelos de predicción para detectar la carga cognitiva durante la conducción. Los modelos lograron una tasa de exactitud al clasificar los datos por debajo del 90%. En este capítulo el modelo de predicción que se presenta obtiene una tasa de exactitud en la predicción del 93.9%.

El modelo propuesto se desarrolla en tres principales módulos. Primero, las señales EEG generan gran cantidad de información llegando a ser complejo y robusto su tratamiento. Por ello, se desarrolló una interfaz para recolectar, descomponer, extraer y seleccionar las características espectrales de las señales. Segundo, para organizar la gran cantidad de información generada, se desarrolló un método de agrupación de datos. El objetivo de este método fue optimizar la fase de entrenamiento del clasificador. Por último, se desarrolló el clasificador del modelo para realizar las predicciones.

Los nuevos conjuntos de datos calculados con el método de agrupación fueron analizados con ANOVA F-score para evaluar si existen diferencias significativas entre la información recolectada en los dos experimentos realizados en esta investigación. Los resultados de F-score fueron:  $\theta$  ( $F=0.564$ ),  $\gamma$  ( $F=0.005$ ),  $\delta$  ( $F=4.980$ ),  $\beta$  ( $F=0.152$ ),  $\alpha$  ( $F=0.007$ ) y  $\alpha/\beta$  ( $F=1.556$ ) donde  $\theta$ ,  $\delta$  y  $\theta+\alpha/\beta$  demostrando diferencias significativas entre las muestras recolectadas en cada experimento considerando que cada conjunto contiene información relevante que permite distinguir entre el estado de estrés y relajación.

Por último, se discute el desarrollo y evaluación de tres clasificadores desarrollados con los algoritmos de AA SVM, k-NN y RL para predecir la carga cognitiva de los conductores en tiempo real. Cada algoritmo fue desarrollado utilizando diversos método y técnicas para obtener la mejor configuración de parámetros que se ajuste a los datos de las señales EEG. Es importante considerar que los modelos de predicción son sensibles a las configuraciones de cada algoritmo.

Los resultados de cada uno de los clasificadores fueron analizados y comparados utilizando diversas métricas para obtener el mejor modelo de predicción que se ajuste a la información siguiendo esta metodología.

## 7. CONCLUSIONES

La actividad del monitoreo del estado cognitivo de los conductores de vehículos tiene gran potencial para disminuir la probabilidad de accidentes de tráfico, causados por el exceso de estrés o de cansancio durante la conducción.

En este capítulo, se describe paso a paso el proceso de desarrollo del modelado de los datos EEG para construir un modelo de predicción de carga cognitiva baja y alta para estimar y prevenir el estrés o la relajación extrema durante la conducción de vehículos. El modelo

fue desarrollado utilizando la información fisiológica de la señal EEG recolectada en tiempo real de 12 conductores.

Los resultados obtenidos demostraron que la metodología propuesta puede predecir de manera exitosa la carga cognitiva alta o baja durante la conducción utilizando la información extraída de las señales EEG como indicadores cognitivos para entrenar el modelo.

Se observó, que el método de agrupación de datos propuesto optimiza la fase de ajuste de los parámetros  $C$  y  $\gamma$  del algoritmo SVM, permitiendo aprender el comportamiento de la información extraída de las señales EEG y predecir los estados cognitivos con una tasa de exactitud del 93.94% con SVM tipo RBF y 90.9% con SVM kernel lineal comparado con los algoritmos k-NN y RL.

Por último, los resultados del experimento muestran que obtener un alto porcentaje de clasificación en un modelo de predicción que en nuestro caso es del 93.94%, depende de varios factores, desde aplicar una buena técnica de recolección de los datos hasta la última etapa de desarrollo del clasificador.

En este capítulo se propone principalmente una metodología que permite reestructurar la información de la señal EEG para crear un nuevo conjunto de datos con características relevantes para el reconocimiento de patrones que facilitan el proceso de entrenamiento y aprendizaje del clasificador para aumentar la eficiencia predictiva del modelo. Es importante considerar que para generar modelos precisos es necesario tener en cuenta todas las etapas del ciclo de vida para el desarrollo de proyectos de minería y ciencia de datos.

Con el uso de un nuevo conjunto de datos, con menos componentes que el conjunto original, resultó beneficioso incrementar la tasa de predicción, reduciendo el uso de la memoria y el tiempo de cálculo. Este resultado asegura la estabilidad del modelo de predicción para implementarlo en entornos reales de conducción de vehículos.

Teniendo en cuenta lo anterior, el trabajo futuro de esta investigación se concentrará en mejorar el modelo de carga cognitiva implementando la información recolectada de las autoevaluaciones para desarrollar un modelo más estable y con mayor tasa de precisión en la predicción de la carga cognitiva, así como también, se implementará nuevos conjuntos de datos, tales como, medidas de rendimiento vehicular para validar la información recolectada de las señales EEG.



## CAPÍTULO IV

### SEGUNDA FASE DEL DESARROLLO DEL MODELO DE PREDICCIONES: SELECCIÓN DE CARACTERÍSTICAS Y DESARROLLO DEL CLASIFICADOR

En este capítulo, se presenta un nuevo modelo para el reconocimiento de patrones utilizado para identificar estados de baja y alta carga cognitiva en los conductores de vehículos definido GALoRSI. GALoRSI combina las técnicas de algoritmos genéticos, regresión logística y análisis estadísticos para identificar y seleccionar la información extraída de las señales EEG con el fin de encontrar un conjunto de características con información relevante capaz de identificar o describir estados cognitivos de la persona.

Las características seleccionadas por el GALoRSI fueron implementadas como índices para el reconocimiento de patrones en cuatro clasificadores para predecir dos estados cognitivos: carga cognitiva baja y alta. Los resultados mostraron que las características seleccionadas por GALoRSI maximizan la capacidad predictiva del modelo de predicción.

La información de este capítulo fue publicada en el artículo Becerra-Sánchez, P., Reyes-Munoz, A., & Guerrero-Ibañez, A. (2020). Feature selection model based on EEG signals for assessing the cognitive workload in drivers. *Sensors*, 20(20), 5881.

#### 1. INTRODUCCIÓN

Conducir un vehículo es una actividad compleja expuesta a demandas que cambian continuamente debido a diferentes factores, como límites de velocidad [1], obstáculos en la vía [2], tráfico vehicular [2], gestión del GPS [3], entre otros. Al realizar esta actividad, se requiere un alto grado de concentración por parte de los conductores, incrementando los niveles de carga cognitiva y causando accidentes de vehículos al mínimo descuido [4]. En los últimos años, se han utilizado diversas herramientas para evaluar la demanda de la carga cognitiva generada en los conductores de vehículos. Las herramientas más utilizadas son medidas subjetivas [68][69], medidas de rendimiento vehicular [95][96] y medidas fisiológicas [7] donde las señales EEG son las más utilizadas para identificar estados cognitivos debido a su alta precisión [31].

Las señales EEG permiten analizar el comportamiento de la actividad cerebral de una persona en tiempo real, sin embargo, este tipo de señales fisiológicas generan grandes volúmenes de datos por segundo, que a su vez incrementa proporcionalmente conforme al tipo de dispositivo y su número de electrodos, resultando complejo y robusto el análisis y



tratamiento de la información [64][61]. Por ello, trabajar con señales EEG para desarrollar modelos de predicción en tiempo real es una tarea compleja.

Uno de los principales desafíos que enfrentan las señales EEG es encontrar la información adecuada que permita identificar estados cognitivos. En este tónico, se han desarrollado métodos de selección de características para el reconocimiento de patrones en la información de las señales EEG. Los algoritmos de selección de características (ASC) tienen como objetivo principal encontrar características con información relevante, es decir, encontrar datos que puedan describir un evento a estudiar, además, permiten eliminar información redundante o irrelevante y disminuir la dimensionalidad del conjunto original, maximizando el rendimiento predictivo del modelo [97].

Muchas investigaciones han desarrollado modelos predictivos utilizando ASC para buscar patrones en la información. En [98] presentan un modelo basado en computación blanda para seleccionar y clasificar la información de las señales EEG logrando una tasa de precisión del 93.05% y 85%. El sistema obtuvo un bajo rendimiento en entornos de tiempo real. En [99] presentan un modelo para el reconocimiento de emociones basado en redes neuronales convolucionales para extraer y clasificar las señales EEG logrando una tasa de precisión del 93.72% y 97.73%. El sistema mejoró el desempeño del modelo en un 1% y 2%. En [100] proponen un modelo que determina los estados emocionales basado en una red de funciones multinivel que extrae características de las señales EEG y clasifica los estados emocionales logrando una tasa de precisión del 97.97% y 94.59%. El método presentó complejidad en el diseño de red. En [66] presentan un método de selección de características basado en la información mutua normalizada logrando un 74.41% y 73.64% de precisión en la clasificación de los datos. El sistema mejoró ligeramente la tasa de clasificación. En [101] proponen un sistema de selección y clasificación de señales EEG basado en patrones espaciales comunes obteniendo una precisión del 84.8%. El sistema no incluye un método de regularización de parámetros y no considera entornos de tiempo real. En [102] utilizan ocho algoritmos de selección de características y aprendizaje automático para reducir el número de características y mejorar el rendimiento del modelo logrando una precisión del 97.74%. Algunos algoritmos redujeron ligeramente su desempeño después de aplicar las técnicas de selección de características. En [103] se propone un sistema para seleccionar y clasificar el estrés mental implementando técnicas estadísticas y los algoritmos SVM, naive bayes y perceptrón multicapa, logrando una precisión del 92.85%. Este sistema utiliza información de un pequeño conjunto de datos. En [104] desarrollaron un sistema de reconocimiento de emociones para identificar estados afectivos basado en las señales EEG implementando diversos ASC y máquina de vectores de soporte (SVM- Support Vector Machine). El sistema obtuvo un 75% y 71.21% en la predicción de la información. El modelo presentó problemas para identificar las emociones negativas a causa del diseño del experimento. En [105] los autores presentan una técnica basada en cuaternión (Quaternion) que analiza las señales EEG y extrae las características correspondientes a la actividad cognitiva logrando un 86.44% de precisión. El modelo analiza sólo pequeños conjuntos de muestras, aumentando el tiempo de análisis y procesamiento de la información. En [106]

presenta un método de clasificación basado en patrones espaciales comunes para la extracción de características y utilizaron SVM para clasificar la información logrando 86,3%, 91,8% y 92.0% de precisión. En [107] desarrollaron diferentes clasificadores basados en las señales EEG implementando el análisis de discriminación lineal, análisis de discriminación cuadrática, k vecino más cercano (k-NN), algoritmos bayesiano y SVM con kernel tipo lineal y de función de base radial (RBF- Radial Basis Function). SVM obtuvo la mejor tasa de predicción con un 82.14% donde algunas técnicas implementadas para la extracción de la información causaron pérdidas de datos vitales. En [108] los autores proponen un sistema para detectar niveles de vigilancia utilizando señales EEG combinando los algoritmos SVM con optimización de partículas múltiples. El sistema obtuvo una precisión máxima del 84.1% presentando problemas de bajo rendimiento debido a la complejidad de los datos. En [13] los autores desarrollaron un modelo para predecir la carga mental basado en diversas señales fisiológicas utilizando la función de discriminación lineal. El modelo logró un 85% de precisión. Algunas medidas fisiológicas propuestas no identificaron efectivamente la carga mental afectando el desempeño del modelo. En [109] desarrollaron un modelo basado en los algoritmos de patrón espacial común y aprendizaje extremo para extraer y clasificar la información de las señales EEG obteniendo un 87.5% de precisión. El modelo presentó una alta sensibilidad a la configuración del kernel, afectando su rendimiento. En [97] implementan el algoritmo evolutivo para la selección de la información obteniendo un 96.97% de precisión en la clasificación. Este modelo presenta problemas de convergencia prematura en el algoritmo evolutivo. Finalmente, en [1] implementan un algoritmo bayesiano de bajo aprendizaje y SVMRBF para seleccionar y clasificar los datos logrando un 89.7% de precisión. Este modelo, presenta problemas en la fase de recolección de los datos afectando los resultados de predicción.

En resumen, aunque en los últimos años se han propuesto varios modelos para el reconocimiento de patrones utilizando ASC basados en señales fisiológicas. Algunos modelos descritos anteriormente se han basado en técnicas tradicionales que reducen un porcentaje mínimo las características del conjunto original obteniendo modelos de predicción robustos. Otros modelos, han analizado la información de una señal específica para comparar características determinadas y descartar información relevante. En este capítulo, se presenta el modelo de selección de características para el reconocimiento de patrones utilizando la información de las señales EEG denominado GALoRSI (Genetic Algorithms and Logistic Regression for the Structuring of Information). GALoRSI combina los algoritmos genéticos (AG) y de regresión logística (RLo) para crear una nueva función de ajuste basada en técnicas de aprendizaje automático y análisis estadísticos para explorar la información EEG, identificando las características críticas que contribuyan al reconocimiento de los estados cognitivos, estructurando un nuevo conjunto de datos capaz de optimizar el proceso de clasificación del modelo predictivo. El conjunto de datos obtenido al aplicar el algoritmo de selección de características es utilizado como un índice para el reconocimiento de estados cognitivos en el modelo.

Los AG son procedimientos computacionales adaptativos o evolutivos inspirados en la teoría de la evolución natural de Charles Darwin [110]. Los AG se han utilizado para resolver problemas de optimización en modelos complejos, buscando el mejor conjunto de características, especialmente cuando el espacio de búsqueda es grande y complejo [103].

Los AG tradicionales se basan en el proceso evolutivo, que consiste en realizar búsquedas multidireccionales en paralelo para seleccionar, combinar y evaluar las características hasta encontrar un conjunto de datos que mejor se ajuste a la resolución del problema [111]. El proceso de búsqueda tradicional de AG, resulta robusto e ineficiente en modelos con grandes volúmenes de datos o en sistemas de tiempo real, debido a que AG realiza  $k$  combinaciones de características simultáneamente descartando posibles soluciones y afectando la efectividad, tiempo de ejecución y coste computacional del modelo [112].

Para hacer frente a estos problemas, en este capítulo se propone un nuevo diseño de la función de ajuste de los AG basada en el rendimiento del clasificador RLo. A diferencia de los algoritmos evolutivos tradicionales, GALoRSI no necesita realizar largas búsquedas multidireccionales en paralelo para obtener la información de las características seleccionadas. GALoRSI recibe la información del clasificador RLo para determinar la dirección de búsqueda a una solución óptima.

RLo es un algoritmo de aprendizaje automático basado en técnicas estadísticas y puede ser utilizado con dos propósitos: algoritmo predictivo y/o como algoritmo explicativo. RLo como algoritmo predictivo, consiste en predecir un evento  $Y$  basado en un vector de entrada  $x$  y una variable categórica  $y$ . RLo como algoritmo explicativo, es utilizado para describir la relación que existe entre una variable dependiente  $y$  y un conjunto de variables independientes  $x$ .

En GALoRSI, el algoritmo RLo es implementado utilizando los dos enfoques donde se calcula el peso de las características seleccionadas, estimando la probabilidad de una variable de pertenecer a un grupo para obtener la tasa de desempeño del conjunto de datos y el nivel de significancia de cada elemento donde las mejores características son seleccionadas para construir nuevas y mejores poblaciones. Esta técnica permite que el modelo vaya tomando decisiones basadas en la existencia e importancia de las características. Además, RLo es un algoritmo caracterizado por su efectividad y simplicidad al trabajar con grandes conjuntos de datos, sin requerir elevados recursos computacionales para realizar la ejecución del algoritmo.

La información seleccionada por GALoRSI fue implementada para el reconocimiento de patrones en cuatro clasificadores desarrollados con SVM con kernel lineal y RBF, regresión lineal (LR) y  $k$ -vecinos más cercanos ( $k$ -NN) para analizar y compara el algoritmo que mejor se integra a GALoRSI creando un modelo predictivo con una alta tasa de predicción.

Las principales contribuciones de este capítulo se resumen de la siguiente manera: 1) Se presenta un nuevo método de recopilación de la información basado en técnicas estadísticas para construir un conjunto de datos EEG definido como espacio de búsqueda que GALoRSI utilizará para explorar la información. 2) Se presenta el nuevo modelo de selección de características y estructuración de la información denominado GALoRSI. 2.1) Se define una nueva estructura cromosómica para dirigir la búsqueda de las características. 2.2) Se propone

una nueva función de ajuste basada en el rendimiento del clasificador RLo para determinar la dirección de búsqueda de AG. 2.3) Se propone una nueva técnica para la selección de los cromosomas. 2.4) Se presenta un método para estructurar la información de múltiples canales que soporta conjuntos de datos de diversos tamaños. 3) Se presenta una nueva metodología para etiquetar los datos que calcula el rango del intervalo de la información EEG para evaluar los estados cognitivos del sujeto.

El resto del capítulo se organiza de la siguiente manera. La sección 2 describe la metodología. La sección 3 presenta la experimentación y materiales implementada. Los resultados se presentan en la sección 4. Finalmente, las conclusiones y discusiones se encuentran en la sección 5.

## 2. METODOLOGÍA

Fue utilizada la información proveniente de las señales EEG recolectadas de las personas mientras se enfrentaban a dos escenarios de conducción de un vehículo. También, fueron recolectadas simultáneamente las informaciones de las medidas subjetivas (NASA-TLX (Task Load Index), ISA (Instantaneous Self-Assessment)) y de rendimiento vehicular (tasa de error (TE)) con el objetivo de analizar el comportamiento de los datos y examinar los estados cognitivos experimentados por los sujetos.

Para analizar la información fisiológica, las señales EEG fueron procesadas utilizando la densidad de espectro de potencia (PSD- Power Spectral Density) para extraer las características más representativas en el contexto de la carga cognitiva definidas como bandas de frecuencia [34]. Estas características son: Delta (0.5–4 Hz), Theta (4–8 Hz), Alfa (8–12 Hz), Beta (12–30 Hz) y Gamma (30-100 Hz).

Una vez obtenidas las bandas de frecuencia, se implementó en cada una de las medidas utilizadas en esta investigación la prueba estadística T-student con el objetivo de analizar el impacto de los experimentos aplicados a la misma población en dos momentos distintos e identificar diferencias estadísticamente significativas entre la información recolectada [113], es decir, si las personas experimentaron niveles de baja y alta carga cognitiva. Los resultados de la prueba estadística permitieron establecer un criterio de separación de la información para construir un conjunto de datos definido como espacio de búsqueda que GALoRSI utilizará para explorar la información de las señales EEG.

Además, fue aplicado el análisis de correlación de Pearson para identificar la relación entre ISA, NASA-TLX, TE con la señal EEG y evaluar si el sujeto experimentó interna (con las señales EEG) y externamente (con las medidas ISA, NASA-TLX, ER) dos niveles de carga cognitiva durante los experimentos [28].

Para identificar las características más representativas que nos permita identificar estados cognitivos fue desarrollado GALoRSI. GALoRSI selecciona y evalúa las características para reestructurar un nuevo conjunto de datos que será implementado en cuatro clasificadores desarrollados con los algoritmos supervisados SVMRBF, SVMLineal, k-NN y RL.

La arquitectura general del modelo para predecir carga cognitiva baja y alta se muestra en la Figura 8.




Figura 8 Diagrama del modelo para predecir de estados de carga cognitiva alta y baja de conductor del vehículo

## 2.1. Análisis Estadístico.

T-Student es una prueba paramétrica utilizada para analizar el impacto de dos experimentos aplicados a la misma población. La prueba consiste en calcular y comparar las medias de las dos muestras y analizar si existen diferencias estadísticamente significativas entre ellas, comprobando o descartando una hipótesis establecida [114].

T-Student fue aplicada en las medidas ISA, NASA-TLX y TE, así como también, en las bandas de frecuencia delta, theta, alfa, beta y gamma, donde cada variable fue contrastada con los datos recolectados durante los dos experimentos. Las hipótesis establecidas en este estudio fueron

$H_0$ : No existen diferencias significativas entre la información recolectada durante los dos experimentos

$H_1$ : Existen diferencias significativas entre la información recolectada durante los dos experimentos

donde si el valor de la probabilidad de error ( $p$ ) de las muestras es mayor que el nivel de significancia de  $\alpha = 0.05$ , se acepta la hipótesis establecida en  $H_0$ . Si el valor de la probabilidad de error ( $p$ ) de las muestras es menor o igual que el nivel de significancia, se acepta la hipótesis establecida en  $H_1$ .

Con los resultados de la T-student fue establecido un criterio de separación de la información para construir el espacio de búsqueda que GALoRSI utilizará para explorar la información de las señales EEG. El criterio se definió como Ecuación 13

$$p_{EEG} \leq \alpha \therefore \text{espacio de búsqueda}$$

Ecuación 13

donde las muestras con un valor de  $p \leq \alpha$  se establecerán dentro del espacio de búsqueda.

Además, como en [40][115][116][117][118] en esta investigación fue utilizada la correlación de Pearson para identificar la importancia que tiene una variable sobre otra, calculando el índice que mide el grado de relación entre las variables. Se definió la hipótesis donde si las señales EEG se correlacionan con las medidas subjetivas y de rendimiento vehicular, el sujeto experimenta de manera interna y externa dos niveles de carga cognitiva.

La correlación de Pearson fue aplicada entre las medidas ISA, NASA-TLX, TE, delta, theta, alfa, beta y gamma donde el análisis se realizó correlacionando el promedio del valor obtenido de cada sesión por medida (8 medidas \* 2 sesión) donde si el rango de correlación es 0, no existe correlación entre medidas. Si el rango de correlación es -1 o +1, existe una correlación (+,-) perfecta [72].

## 2.2. GALoRSI

En esta sección, se presenta la arquitectura del algoritmo GALoRSI como se muestra en la Figura 10. GALoRSI propone un nuevo diseño en la estructura del cromosoma y una nueva función de ajuste basada en regresión logística (RLo) que modela el peso de las características para determinar la dirección de búsqueda de nuevos elementos. También, se propone una nueva técnica de selección para identificar de manera eficiente el mejor conjunto de características.

El algoritmo consiste en cinco etapas definidas como población, función de ajuste, selección, cruce y mutación que interactúan entre ellas hasta obtener el índice de predicción. A continuación, se presenta cada una de las etapas.

### 2.2.1. Población

La población es un conjunto de datos definidos como individuos o cromosomas que representan una posible solución al problema que se desea resolver. Un cromosoma está formado por varios elementos establecidos como genes que son seleccionados del espacio de búsqueda por primera vez al azar y después se van modelando a través de la función de ajuste como se presenta en la Figura 9.

```
individual = [1 for i in range(len(allFeatures.columns))]
Chromo_parameters = getFitness(individual, X_train, X_test, y_train, y_test)
```

Figura 9 Creación de la población y evaluación

Para generar los cromosomas, se construyó una matriz definida como espacio de búsqueda donde cada elemento de la matriz presenta un gen que conforma al cromosoma. El espacio de búsqueda es definido como se presenta en la Ecuación 14

$$\text{Espacio Búsqueda} = [\Delta_{ch_{1...n}}, \Theta_{ch_{1...n}}, \beta_{ch_{1...n}}, \Gamma_{ch_{1...n}}]$$

Ecuación 14

cada elemento del espacio de búsqueda es un canal. Los canales de la banda delta se organizan primero, seguido de los canales de las bandas theta, alfa, beta y gamma siguiendo el orden del rango de frecuencia.  $ch_n$  representa los canales utilizados en esta investigación y son definidos en la Ecuación 15

$$ch_n = [AF3, AF4, F3, F7, F8, FC5, O2, P8, T8]$$

Ecuación 15

donde  $ch_n$  debe cumplir el criterio de selección  $p_{Band_{ch}} \leq a \because \in \text{Espacio Búsqueda}$ . En este estudio, fueron implementados 9 canales relacionados por identificar la fatiga durante la conducción de un vehículo [119]. El formato establecido para el espacio de búsqueda es bandas de frecuencia \* canal \* número de muestra ( $5 * 9 * 8210$ ). Toda la información fue normalizada en un rango de  $\{0,1\}$ .

Es definida una nueva estructura cromosómica que contiene los elementos que conforman al cromosoma y la información que evalúa al cromosoma en función al tipo de dato y el problema a resolver. La estructura general del procedimiento de codificación se presenta en la Figura 11.

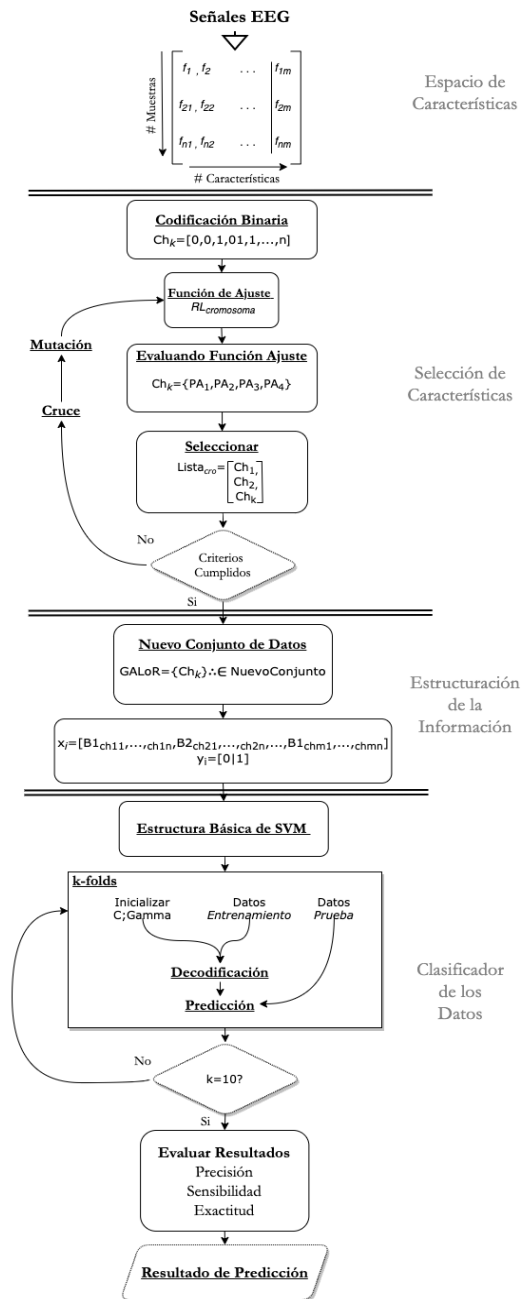


Figura 10 Arquitectura del modelo GALoRSI para el reconocimiento de patrones basado en algoritmos genéticos y regresión logística






Figura 11 Estructura del cromosoma conformado por la información de los genes seleccionados y el peso de cada

donde  $gen_i$  son los genes del cromosoma que se codifican en una cadena binaria  $gen \in \{0,1\}$   $i = 1,2, \dots, n$  donde si el valor del gen es 1 indica que la característica es seleccionada para formar el nuevo cromosoma y continuar el proceso evolutivo.  $p_n$  son los parámetros de adaptación utilizados como criterios de evaluación para determinar si el cromosoma continuo en el proceso evolutivo o no. Los números de adaptación ( $NA$ ) evalúan el cromosoma de manera grupal e individual calculando parámetros de tipo predictivos y estadísticos.

### 2.2.2. Función de Ajuste

La función de ajuste ( $FA$ ) evalúa la calidad de cada cromosoma para encontrar la mejor combinación de genes y preservar una alta diversidad genética en la población.  $FA$  calcula para cada cromosoma los  $NA$  basados en el algoritmo de RLo donde cada parámetro explora las propiedades del cromosoma, la relación que existe entre sus elementos y la capacidad para competir con otros cromosomas.

RLo es un algoritmo que puede ser utilizado como algoritmo predictivo y/o como algoritmo explicativo. RLo como algoritmo predictivo utiliza la variable de entrada  $x$  y una variable categórica  $y$  para entrenar el modelo y predice el valor de  $Y$  donde sí se obtiene un nuevo vector de entrada  $X$ , el modelo deberá de ser capaz de predecir su valor  $Y$  por lo tanto  $[x, y] \in X * Y$  [80].

RLo como algoritmo explicativo, describe la relación entre una variable dependiente  $y$  y variables independientes  $x$ . Para calcular la relación entre variables, RLo modela el logaritmo de la probabilidad de pertenecer a cada grupo como se muestra en la Ecuación 16

$$-Z = [\beta_0, \beta_1 x_1, \dots, \beta_n x_n]$$

Ecuación 16

donde  $x_n$  es el vector de entrada correspondiente a las variables independientes  $x$ ,  $\beta_0$  es la constante del modelo y  $\beta_n$  son los coeficientes logísticos calculados para cada elemento incluido en el modelo. Los valores de  $\beta_0$  y  $\beta_n$  son estimados calculando la función logit de cada variable independiente  $x$  para determinar el ajuste global del modelo y el nivel de significación individual de cada variable  $x$ .



En esta investigación, RLo fue implementada utilizando los dos enfoques para definir los parámetros de adaptación que evaluarán a cada cromosoma de manera grupal y cada elemento que lo conforma. La Ecuación 17 presenta el modelo RLo construido

$$\frac{1}{1 + e^{-(\beta_0 + \text{Banda1}_{canales1} + \text{Banda2}_{canales2} + \dots + \text{Banda}x_{canalesx})}}$$

donde

$$\text{Cromosoma} = (\beta_0 + \sum_{i=1}^n \beta_i \text{Bandas}_{canales})$$

Ecuación 17

donde  $\beta_0$  es la intersección,  $\beta_{bandas_{canales}}$  representa los canales seleccionados del cromosoma.  $\beta_i$  es el coeficiente de estimación calculado para cada variable  $\beta_{bandas_{canales}}$ , el cual determina la importancia de la información proporcionada por cada característica en función del ajuste global del cromosoma generado. En la Ecuación 18 se presenta el modelo cromosómico general implementando todos los elementos del espacio de búsqueda

$$\begin{aligned} chromosome = & 0.0165 + (-97.489) * T_{AF3} + (-0.969) * T_{AF4} + 1.407 * T_{F3} + 3.668 * T_{F7} + 0.484 * T_{F8} + (-5.119) * T_{FC5} + (-1.347) * T_{O2} + (0.688) \\ & * T_{P8} + 0.738 * T_{T8} + (0.298) * D_{AF3} + 0.764 * D_{AF4} + (-1.872) * D_{F3} + 2.429 * D_{F7} + (-3.934) * D_{F8} + 4.361 * D_{FC5} + 2.538 * D_{O2} + (- \\ & 1.247) * D_{P8} + (-1.720) * D_{T8} + (-1.652) * A_{AF3} + 1.560 * A_{AF4} + 2.203 * A_{F3} + (-0.832) * A_{F7} + 1.481 * A_{F8} + (-2.270) \\ & * A_{FC5} + 1.806 * A_{O2} + 1.349 * A_{P8} + 2.319 * A_{T8} + (-0.165) * B_{AF3} + 0.855 * B_{AF4} + 1.550 * B_{F3} + 1.393 * B_{F7} + (-1.542) * B_{F8} + (-6.378) \\ & * B_{FC5} + 2.311 * B_{O2} + 2.245 * B_{P8} + 1.114 * B_{T8} + (-0.964) * G_{AF3} + 0.133 * G_{AF4} + (-0.076) * G_{F3} + 0.274 * G_{F7} + (-0.565) * G_{F8} + \\ & 1.571 * G_{FC5} + 0.053 * G_{O2} + (-0.079) * G_{P8} + (-0.377) * G_{T8} \end{aligned}$$

Ecuación 18

donde los valores de  $\beta_0$  y  $\beta_n$  son estimados a partir de cada banda de frecuencia y representa el ajuste global del espacio de búsqueda, donde  $\beta_i$  proporciona el valor de la importancia de cada característica y examina la probabilidad del resultado de los parámetros  $NA$  a medida que cambien los elementos del cromosoma.

Los parámetros  $NA$  que evaluarán la calidad del cromosoma serán calculados para cada cromosoma generado. Estos parámetros son: exactitud entre el ajuste de los elementos del cromosoma, tasa de error en la predicción de los elementos, número de elementos (genes) que conforman el cromosoma y los elementos significativos de cada cromosoma. A continuación, son explicados cada uno de ellos.

La exactitud mide el grado de cercanía del resultado obtenido de una medición con el valor correcto o establecido [120]. Esta métrica permitirá saber si las muestras seleccionadas como relevantes por el algoritmo propuesto, tienen una alta tasa de veracidad, es decir, que permitan identificar los estados cognitivos analizados. La exactitud es calculada analizando el ajuste de los elementos del cromosoma para obtener la tasa de predicción como se presenta en la Ecuación 19

$$\frac{\text{muestras correctamente predichas por el conjunto de datos}}{\text{Total de muestras predichas por el conjunto de datos}}$$

Ecuación 19

donde se evalúa el número de muestras predichas correctamente dividido entre el número total de muestras calculadas. Los valores tienen un rango de entre [0,1] donde 1 es el valor establecido como alto nivel de exactitud en la tasa de predicción.

La tasa de error en la predicción de los elementos cuantifica el error en la predicción de cada cromosoma, evaluando la cantidad de predicciones que fueron realizadas incorrectamente. Es calculada como se presenta en la Ecuación 20

$$TR = Y - Y'$$

Ecuación 20

donde se calcula la diferencia entre los valores reales  $Y$  y los valores predichos  $Y'$ . El rango de valores va de [0,1] donde los valores cercanos a 0 indicarán que el cromosoma obtuvo una menor tasa de error en la predicción.

El número de elementos que conforman el cromosoma evalúa la cantidad de elementos que fueron seleccionados para construir el cromosoma. El objetivo de este parámetro es que el cromosoma esté conformado sólo con los elementos que sean capaces de describir el comportamiento de los datos descartando elementos innecesarios para disminuir la probabilidad de error, tiempo de análisis y ejecución del algoritmo.

El parámetro de elementos significativos de cada cromosoma evalúa la contribución individual de cada uno de los elementos del cromosoma analizando la variable  $y$  y comparando su valor  $p$  con el nivel de significancia de  $\alpha = 0.05$ . Si el valor  $p$  de la variable es menor o igual que al nivel de significancia se concluye que hay una asociación estadísticamente significativa entre las variables  $[x, y]$  donde la variable evaluada es relevante y deberá permanecer en el cromosoma final.

En la Figura 12 se muestra la función de ajuste construida para el algoritmo de selección de características.

```
def getFitness(individual, X_train, X_test, y_train, y_test):

    chro = [index for index in range(len(individual)) if individual[index] == 0]

    X_trainnotempty = X_train.drop(X_train.columns[chro], axis=1)
    X_testnotempty = X_test.drop(X_test.columns[chro], axis=1)

    # Apply logistic regression on the data and calculate fit
    C_param_range = [0.00001,0.0001, 0.001, 0.01, 0.1, 1, 10, 100, 1000,10000]
    for i in C_param_range:
        clf = LogisticRegression( C = i, random_state=0)
        clf.fit(X_trainnotempty, y_train)
        predictions = clf.predict(X_testnotempty)
        accuracy = accuracy_score(y_test, predictions)

    # Calculating the significant value of each element
    pvalue=[(Rlopvalue(clf, X_trainnotempty))]

    # Return calculated accuracy as fitness
    return (accuracy,pvalue)
```

Figura 12 Código de la Función de Ajuste

### 2.2.3. Selección

Este proceso consiste en seleccionar, ordenar y construir una lista de cromosomas utilizando el criterio establecido en los parámetros  $NA$  como se describe en la Ecuación 21. Este proceso inicia comparando los valores de  $NA$  de cada cromosoma de la misma generación donde el cromosoma que tenga la mayor tasa de ajuste con una menor tasa de error será posicionado al principio de la lista. Si los valores de estos parámetros coinciden al realizar la comparación de los cromosomas, tendrá mayor prioridad el cromosoma que tenga menor número de elementos.

Este mecanismo de selección se realiza  $t$  veces por generación donde en cada  $t$  se produce una comparación para identificar y recolectar el mejor cromosoma, reemplazando a los cromosomas antiguo con un menor valor de  $NA$  permitiendo elegir individuos que contengan información útil pero que no obtuvieron el valor máximo de adaptación en comparación con el resto de la población.

En la Figura 13 se muestra parte del código utilizado para construir la Ecuación 21.

$$\begin{aligned}
 Cro_{11} &= \{x_{ban_{11}}, x_{ban_{12}}, \dots, x_{ban_{1n}}, [x_{NAEXA}, x_{NATR}, x_{NANG}, x_{NAES}]\} \\
 Cro_{12} &= \{x_{ban_{21}}, x_{ban_{22}}, \dots, x_{ban_{2n}}, [x_{NAEXA}, x_{NATR}, x_{NANG}, x_{NAES}]\} \\
 Cro_{1m} &= \{x_{ban_{m1}}, x_{ban_{m2}}, \dots, x_{ban_{mn}}, [x_{NAEXA}, x_{NATR}, x_{NANG}, x_{NAES}]\} \\
 &\quad \vdots \\
 Cro_{1n} &= \{x_{ban_{n1}}, x_{ban_{n2}}, \dots, x_{ban_{nn}}, [x_{NAEXA}, x_{NATR}, x_{NANG}, x_{NAES}]\}
 \end{aligned}$$

donde

$$Cro_{1m}[x_{APAcc}, x_{APEt}, x_{APNG}] > Cro_{1n}[x_{APAcc}, x_{APEt}, x_{APNG}] \therefore Lista[Mayor Prioridad]$$

Ecuación 21

```

for individual in BestElment:
    testAccuracy = individual.fitness.values
    validationAccuracy = getFitness(individual, X_trainAndTest, X_validation, y_trainAndTest, y_validation)
    testAccuracyList.append(testAccuracy[0])
    validationAccuracyList.append(validationAccuracy[0])
    individualList.append(individual)

```

Figura 13 Selección y organización de los cromosomas basado en los parámetros NA

Los cromosomas que tengan elementos con valor de  $x_{ban_{mn}} < a$  serán unidos en un mismo vector para construir un nuevo cromosoma y heredarlo a la próxima generación como se observa en la Figura 14. Este proceso va direccionando la selección de los elementos para formar nuevos cromosomas con mejores propiedades, seleccionando aquellas características con información relevante.

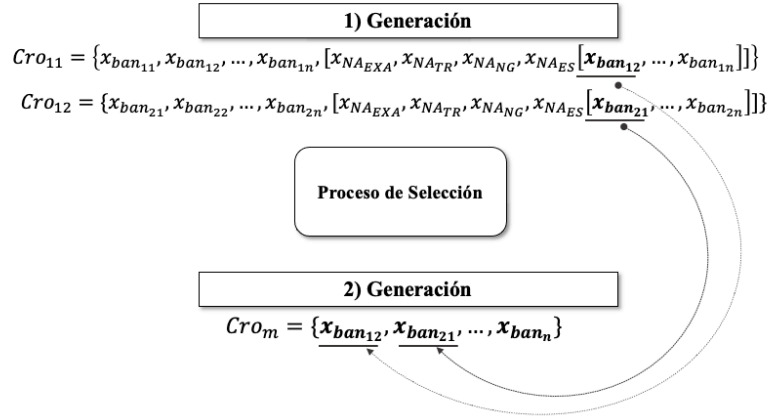


Figura 14 Sistema de selección de elementos para construir nuevos cromosomas con mejores propiedades

### 2.2.4. Cruce

Una vez generada la lista cromosómica inicia el proceso de reproducción con el cruce entre cromosomas. El objetivo del cruce es intercambiar los genes de los cromosomas hasta que se alcanza un punto de cruce, es decir, hasta que se obtenga un nuevo cromosoma con mejores propiedades que los padres. El cruce generalmente se aplica con una alta tasa de probabilidad ( $P_c=1.0$ ) debido a que es el encargado de que ocurra el apareamiento en cada cruce, es decir, indica el porcentaje de cuántas parejas se elegirán para el apareamiento donde si la probabilidad de cruce es del 100%, entonces toda la descendencia se realiza mediante cruce. Si es 0% no se realiza cruce entre cromosomas [121].

Como se observa en la Ecuación 22 esta fase consiste en cortar el cromosoma en dos puntos seleccionados para generar con ellos nuevos segmentos donde se elige el segmento central de uno de los padres y el segmento lateral del otro padre para generar los cromosomas descendientes [122]. El cruce da la posibilidad de recombinar todas las partes del cromosoma para generar mejores cromosomas que en la población inicial no fueron creados.

$$\begin{array}{l}
 \left[ \begin{array}{l} Cro_1 \\ Cro_2 \\ Cro_3 \\ Cro_4 \\ \vdots \\ Cro_n \end{array} \right] \rightarrow \\
 \rightarrow \quad \begin{array}{ccc} Cro_1 & Cro_2 & \rightarrow Cro_{hijo_1} \quad Cro_{hijo_2} \\ [0010101] & [1010101] & \rightarrow [0010101][1010101] \end{array}
 \end{array}$$

Ecuación 22

### 2.2.5. Mutación

El objetivo de la mutación es generar un nuevo cromosoma diferente a los padres para mantener la diversidad dentro de la población y evitar la convergencia prematura.

La mutación se realiza después del cruce y consiste en invertir el bit de un gen del cromosoma. Si el valor del dígito original es 0, cambiaría a 1 y viceversa para obtener variabilidad dentro de la población y descartar cromosomas del resto de la nueva población [122].

En esta investigación, la mutación es aplicada al primer elemento del cromosoma donde la probabilidad de mutación deberá ser comparativamente baja, es decir, si se tiene una probabilidad de mutación del 1%, significa que 1 elemento del total que conforma al cromosoma será seleccionado para invertir su valor [123].

### 2.2.6. Normas de Detección

Para detener el proceso de evolución del modelo, se definieron dos normas de detención de las cuales se deberá de cumplir al menos una de ellas para terminar el proceso evolutivo. La primera norma es que el número de generaciones de cromosomas establecidas se ha alcanzado (el número se define basado en la experimentación y en la cantidad de características dentro del espacio de búsqueda). La segunda norma es que el criterio de evaluación de la función de ajuste se cumpla donde exactitud = 1 y tasa de error = 0.

El desarrollo del modelo de selección de características GALoR fue basado en el algoritmo genético DEAP (Distributed Evolutionary Algorithms in Python) [124][125].

### 2.3. Estructuración de la Información

Se construyó un nuevo conjunto de datos basado en los resultados de la selección de las características, integrando los elementos del cromosoma generado como un índice para el reconocimiento de patrones en el modelo de predicciones. En la Ecuación 23 se presenta la estructura general empleada para construir el nuevo conjunto de datos

$$GALoR = \{cromosoma\} \therefore \in \text{Nuevo conjunto datos}$$

Ecuación 23

donde el cromosoma representa el nuevo conjunto de datos definido como  $cromosoma = \{x_i y_i\}_{i=1}^N$  donde  $x_i$  representa las características seleccionadas,  $y_i$  es la categorización de los datos y  $N$  es el número de muestras.  $x_i$  y  $y_i$  están estructuradas como se presenta en la Ecuación 24 definidos para organizar grandes volúmenes de datos EEG de uno o múltiples canales.

$$x_i = [Ban1_{ch11, ch12, \dots, ch1n}, Ban2_{ch21, ch22, \dots, ch2n}, BanX_{chm1, chm2, \dots, chmn}]$$

$$y_i = [0|1]$$

Ecuación 24

donde  $x_i$  contiene los datos de la señal EEG siguiendo el orden del rango de frecuencia y  $y_i$  incluye la información de dos estados cognitivos. En total, se implementan 8210 muestras. En la Figura 15 se presenta la técnica de estructuración de la información basado en el cromosoma obtenido de la selección de las características.

```
x=[x for x, j in zip(names, list(Individual)) if j == 1]
X = pd.DataFrame(allFeatures, columns=x)
```

Figura 15 Modelo de estructuración de la información basado en el cromosoma construido por GALoR

## 2.4. Clasificadores

En esta investigación fueron desarrollados cuatro clasificadores que implementaron las características obtenidas de GALoRSI. Los clasificadores fueron desarrollados en tres etapas utilizando los algoritmos supervisados de SVMRBF, SVMLineal, regresión lineal (RL) y k-NN. A continuación, se presentan las etapas de los clasificadores.

La primera etapa consiste en el preprocesamiento de la información, donde los datos se dividen en dos grupos: entrenamiento y prueba. El 90% de las muestras son utilizadas para entrenar el modelo y el 10% restante para realizar las pruebas. La segunda etapa consiste en construir el modelo a partir del conjunto de datos destinados para entrenar el modelo. En esta etapa se ajustan los parámetros y configuraciones del modelo. La última etapa consiste en evaluar el modelo entrenado utilizando un conjunto de datos destinados sólo para probar el modelo.

Para dividir la información en dos conjuntos (entrenamiento y validación), fue implementada la técnica de validación cruzada k-fold. K-fold es caracterizada por evitar el sobreajuste de los datos durante la construcción del modelo siendo la técnica más utilizada en los estudios de predicción [126]. K-fold divide aleatoriamente los datos en  $k$  subconjuntos de tamaños iguales donde el subconjunto  $k-1$  es utilizado durante la etapa de validación y el resto de los subconjuntos son utilizados en la etapa de entrenamiento. El proceso se repite  $k$  veces donde en cada ciclo se van calculando métricas de rendimiento que evalúan al modelo. Los  $k$  resultados se promedian para obtener una estimación única. Las ventajas de esta técnica son que todos los conjuntos de pruebas son independientes y mejora la fiabilidad de los resultados [127][112]. Para configurar el parámetro  $k$  fue evaluado el ajuste de parámetros del modelo analizando los datos de entrada implementados en este capítulo durante la fase de entrenamiento donde  $k=10$  obtuvo el mejor resultado.

Las métricas utilizadas para evaluar el rendimiento del modelo son sensibilidad y precisión presentadas a continuación. La métrica de sensibilidad evalúa sólo los casos que se clasificaron correctamente como verdaderos durante la predicción del modelo. La sensibilidad es calculada analizando las predicciones realizadas correctamente como carga cognitiva baja (CCB) y predicciones realizadas incorrectamente como carga cognitiva alta (ICA). La Ecuación 25 es definida la métrica de sensibilidad

$$\text{sensibilidad} = \frac{CCB}{CCB + ICA} * 100$$

Ecuación 25

La métrica de precisión se refiere a qué tan cerca están dos o más mediciones entre sí [120]. Se evalúa analizando el total de las predicciones realizadas correctamente como carga

cognitiva baja (CCB) y predicciones realizadas incorrectamente como carga cognitiva baja (ICB). La métrica de precisión es definida como se muestra en la Ecuación 26

$$precisión = \frac{CCB}{CCB + ICB} * 100$$

Ecuación 26

## 2.5. Etiqueta

Los algoritmos supervisados son construidos con un conjunto de datos conformado por dos vectores  $[x, y]$ . El vector  $x$  de tamaño multidimensional es definido como el vector de entrada que contiene la información recolectada durante el experimento. El vector  $y$  de tamaño unidimensional es definido como el vector de etiqueta que contiene valores de entre  $[0,1]$  donde cada valor describe una categoría o evento, por ejemplo (cara = 0, no cara = 1).

En el mundo real los datos no están etiquetados, por ello en los recientes años se han desarrollado índices implementando las bandas de frecuencia  $\delta, \theta, \alpha, \beta, \gamma$  para identificar diferentes estados como se muestra en Tabla 3.

En estas investigaciones utilizan bandas y/o canales de fuentes específicas para evaluar los estados cognitivos de los sujetos descartando información. En esta investigación, se desarrolló una técnica de etiquetado que identifica los niveles de carga cognitiva baja y alta de la información proveniente de las señales EEG para categorizar los datos.

Tabla 3 Índices para calcular diversos estados de las personas utilizando las bandas de frecuencia

Referencia	Estado	Métricas
[58]	Estrés (Lateral Index at Stress)	$LIS = \frac{Right - Left}{Right + Left}$
[128]	Cognitiva-Afectiva (Frontal Asymmetry)	$FA = \ln \frac{\alpha Right AF4}{\alpha Left F3}$
[129]	Engagement	$\frac{\beta}{\alpha + \theta}$
[46]	Alerta/Estrés	$\frac{\theta + \alpha}{\beta}$
[130]	Valencia	$\alpha(FA3) - \beta(F3)$
[130]	Excitación	$\frac{\beta(AF3 + AF4 + F3 + F4)}{\alpha(AF3 + AF4 + F3 + F4)}$
[131]	Alzheimer	$Thr_{up}(x) = avd(x) + 1.5 \cdot stdev(x)$ $Thr_{down}(x) = avd(x) - 1.5 \cdot stdev(x)$
[132]	Desincronización relacionada con eventos	$\frac{band\ power\ refence - band\ power\ test}{band\ power\ reference} * 100$
[133]	Actividad Neuronal	$\frac{\beta}{\theta}$
[134]	Índice de Carga	$\frac{\theta}{\alpha}$
[134]	Ecuanimidad	$\frac{B^2 - \alpha(\alpha - \alpha + \theta)}{B^2 + \alpha(\alpha + \theta)}$



La técnica de etiquetado consiste en definir el umbral inferior y superior del conjunto de datos, calculando el promedio de cada muestra por segundo para obtener un vector de medias. Después, es calculado el valor máximo y mínimo del vector de medias, dividido entre el número de estados cognitivos obtenido así el tamaño del intervalo para cada categoría. En la Ecuación 27 se presenta la función

$$Umbral_{[inferior,superior]} = \frac{Vectormedia_{maxvalor} - Vectormedia_{minvalor}}{Carga\ Cognitivos_{[bajo,alto]}}$$

Ecuación 27

donde  $Vectormedia_{maxvalor}$  y  $Vectormedia_{minvalor}$  representa el valor máximo y mínimo de las muestras del vector de medias,  $carga\ cognitivos$  representa el número de estados cognitivos a evaluar y  $Umbral$  es el tamaño del intervalo superior e inferior para cada estado cognitivo donde la categorización de los datos se realiza como se presenta a continuación

$$Umbral = \begin{cases} x < Intervalo\ CCB_{[superio,inferior]} & 0 \\ x > Intervalo\ CCA_{[superio,inferior]} & 1 \end{cases}$$

donde  $Intervalo\ CCB$  es el valor del intervalo definido para la carga cognitiva baja y  $Intervalo\ CCA$  es el valor del intervalo definido para la carga cognitiva alta.

### 3. EXPERIMENTACIÓN Y MATERIALES

#### 3.1. Diseño del Experimento

Los datos fueron recolectados de 5 sujetos de un rango de edad de 21-35 años y con una licencia de conducir de mínimo 2 años. Los sujetos evitaron consumir alcohol, café o medicamentos por al menos 24 horas antes del experimento.

En los últimos años, los estudios realizados en simuladores de conducción han dominado principalmente por su seguridad del participante, bajo costo y fácil recolección de los datos [135]. Además, en [136][137] destacan que los estudios realizados en un entorno real y simulado de conducción vehicular son igualmente válidos para analizar variables relacionadas con fatiga y estrés del conductor. En este capítulo, los experimentos fueron realizados utilizando el simulador Lane Change Test (LCT) versión 1.2 [138], que simula las condiciones de conducción más frecuentes de un vehículo. LCT está diseñado para medir cuantitativamente el nivel de degradación del rendimiento del sujeto durante la conducción realizando simultáneamente otras tareas secundarias [139][140][141].

LCT consiste en conducir en una carretera de tres carriles con una longitud de 3000 m., a una velocidad máxima de 60 km/h. Durante el trayecto, se van presentando instrucciones para cambiar de carril a través de señales de tráfico que aparecen al lado de la autopista cada 150m. El participante tiene que realizar la actividad indicada por la señal, respetando las



normas de tráfico [142]. El experimento tiene una duración aproximada de 80 min. divididos en tres fases:

- I. Línea base: Al participante se le solicita tomar asiento y colocarse el sensor EEG en la cabeza [42]. El sujeto mantiene los ojos cerrados y es aislado acústicamente durante 10 minutos donde el sensor EEG es activado para recolectar información del estado base del sujeto.
- II. Primera tarea (Tarea\_1): El participante comienza a conducir el vehículo sin ninguna distracción. Durante la conducción, se recolectan las medidas ISA, TE y las señales EEG. Al final, se aplica la prueba NASA-TLX.
- III. Segunda tarea (Tarea\_2): Con el fin de incrementar los niveles de carga cognitiva del sujeto, se aplica el protocolo de inducción de estrés propuesto en [1] como segunda tarea. Esta tarea consiste en que al participante se le menciona una serie de dígitos de manera aleatoria que después tendrá que repetir en voz alta siguiendo el orden del conjunto de números que se le fue dado. Todas las medidas fueron recolectadas en esta etapa.

El protocolo experimental fue aprobado por el comité de ética de la Universidad Politécnica de Cataluña y la Comisión de Investigación del Consejo de Gobierno (Acuerdo no. 45/2015). Los métodos se realizaron de acuerdo con las directrices y reglamentaciones pertinentes. Los pacientes firmaron el consentimiento informado para un protocolo de investigación presentado en el Anexo B.

### 3.2. Medidas Subjetivas

Para evaluar la carga cognitiva percibida por los sujetos durante el experimento, fueron implementadas las medidas subjetivas ISA y NASA-TLX. ISA es un cuestionario que se aplica cada 2 minutos durante el desarrollo del experimento donde el participante debe proporcionar el número que mejor describa su nivel de estrés siguiendo la escala de 1 a 5 propuesta en [143]. Esta escala es definida como: (1) aburrido, (2) relajado, (3) confortable, (4) poco ocupado y (5) muy ocupado. Para calcular la ponderación del cuestionario, se asigna un peso que va del 1 al 10 conforme al nivel de dificultad de la tarea durante el tiempo del experimento donde 1 representa una tarea con baja dificultad y 10 es una tarea con alta dificultad. El peso asignado, es multiplicado por el número proporcionado por el participante y promediado entre las actividades para obtener la ponderación del ISA que va de 1 a 100.

NASA-TLX es una aplicación post-ejercicio que evalúa seis factores definidos como dimensiones que caracterizan la carga subjetiva [144]. Para obtener la escala de NASA-TLX, primero se calcula la puntuación de cada dimensión según la carga cognitiva percibida por el sujeto durante el experimento, después, las dimensiones son comparadas entre ellas y el participante elige la dimensión que tiene mayor relevancia donde el número total de veces que fue elegida la dimensión es definido como su peso específico. La puntuación final de la carga cognitiva se obtiene multiplicando cada puntuación de la dimensión por el peso,

dividiendo la puntuación total de todas las dimensiones entre 15 (el número total de combinaciones entre dimensiones) obteniendo un valor de NASA-TLX que va de entre 1 a 100.

### 3.3. Medidas de Rendimiento Vehicular

El rendimiento vehicular está asociado con la capacidad de mantener el vehículo dentro de los márgenes de seguridad. Para evaluar esta capacidad, en esta investigación fue implementada la medida de tasa de error (TE). TE evalúa el total de actividades que fueron realizadas de manera incorrecta con respecto al total de actividades presentadas durante el experimento. En [66] los autores explican que TE está relacionada con altos niveles de carga cognitiva ya que, entre mayor sea la cantidad de actividades realizadas durante una tarea, mayor será la carga cognitiva incrementando la tasa de error.

Para estimar la tasa de error de cada sujeto fue definida la Ecuación 28 donde se calcula la sumatoria de las actividades realizadas de manera errónea ( $a_e$ ) entre el total de actividades ( $a_{ti}$ ) presentadas durante la tarea\_1 y tarea\_2. En este estudio, cada minuto fue presentada una actividad donde el tiempo total analizado en cada tarea fue de 20 minutos obteniendo 20 tareas.

$$TE = \sum_{i=0}^{a_t=20} \frac{a_e}{a_{ti}}$$

Ecuación 28

donde  $i$  va desde ningún error hasta el número total de actividades presentadas durante el experimento, ( $a$ ) es la actividad definida como cambio de carril durante la simulación y los errores son considerados cuando el sujeto no realiza el cambio de carril indicado.

### 3.4. Recolección y Extracción de las Señales EEG

La señal EEG se adquirió utilizando el sensor Emotiv EPOC de 14 electrodos. El sensor envía la señal de forma inalámbrica a un receptor bluetooth y almacena la información en un archivo edk.dll. Fue desarrollada una aplicación en LabVIEW utilizando el archivo edk.dll para analizar y visualizar la señal EEG en tiempo real, como se muestra en la Figura 16. La información se almacenó en un archivo con la extensión \*.cvs, usando la unidad de medida de microvoltios.




Figura 16 Adquisición de la señal EEG en tiempo real.

Para analizar la información recolectada, se implementó un proceso de extracción de características el cual consiste en transformar las señales originales, en un vector de características que representa el comportamiento de la señal. En la literatura, se distinguen las características en el dominio del tiempo, el dominio de la frecuencia y el dominio de la frecuencia del tiempo [21]. En esta investigación, la señal se analiza en el dominio de la frecuencia utilizando PSD. PSD determina la distribución de la potencia de la señal en un rango de frecuencia, facilitando la extracción de las características de cada canal [35]. Las características más populares de las señales EEG en el contexto de la carga cognitiva son las bandas de frecuencia[34][80]. Estas bandas son: Delta (0.5–4 Hz), Theta (4–8 Hz), Alfa (8–12 Hz), Beta (12–30 Hz) y Gamma (30-100 Hz).

Las señales como tales son sensibles a las actividades llamadas artefactos generadas por los movimientos corporales que alteran la calidad de la señal [72]. Por ello, para eliminar los artefactos, fue utilizado el filtro de tipo Butterworth con un orden 5 para eliminar artefactos bajos en la señal a una frecuencia de corte de 1 a 100 Hz basados en [56][118][145]. Butterworth tiene una mayor respuesta lineal en comparación con otros filtros permitiendo filtrar y descomponer eficientemente las señales de tipo EEG [79].

La Transformada Rápida de Fourier (FFT) se calcula con una ventana de Hanning de 128 muestras a una longitud de  $T = 5s$  para convertir la señal del dominio del tiempo al dominio de la frecuencia y extraer la magnitud del espectro de potencia de las cinco bandas de frecuencia.

Una interfaz fue desarrollada para extraer las bandas de frecuencia. En la Figura 17 se muestra la interfaz donde se observa la distribución de la frecuencia de la señal de cada una de las bandas. El valor máximo de la magnitud del espectro de potencia fue almacenado en un archivo con extensión \*.csv como sugieren en [80]. El formato de los datos obtenido fue

canal \* número\_muestra \* bandas\_frecuencia (9 \* 8210 \* 5). Toda la información fue estandarizada.

Se utilizó un ordenador de 16 GB de RAM con un procesador Intel Core i7 (2.8 GHz) para realizar la recolección y extracción de los datos.




Figura 17 Interfaz desarrollada para extraer las cinco bandas de frecuencia de las señales EEG

### 3.5. Conjunto de Datos y Parámetros

En [31][72][80] sugieren que al combinar la información EEG, proveniente de múltiples bandas de frecuencia, mejora los resultados de predicción construyendo modelos con juicios más confiables y ricos en funciones. Por ello, en esta investigación se proponen siete subconjuntos de datos para analizar el comportamiento de la información, la relación entre las características y el rendimiento del modelo de predicciones.

Los conjuntos de datos fueron construidos basados en cuatro criterios. Primero, toda la información del conjunto de datos fue utilizada como datos de entrada en el modelo. Segundo, se propone un conjunto de datos con información relacionada a un estado cognitivo utilizando una sola banda. En este caso, se selecciona la banda alfa caracterizada por el reconocimiento eficiente de los estados cognitivos [40]. Tercero, se propone construir un conjunto de datos con información relacionada a un estado cognitivo, combinando diversas bandas de frecuencia [39] [146]. Finalmente, se propone construir un conjunto de datos que contenga la información de los dos estados cognitivos combinando diversas bandas de frecuencia[18][147].

En la Tabla 4, se presentan los siete conjuntos de datos establecidos en esta investigación donde todos los conjuntos de datos siguieron el criterio de separación de la información estadístico donde  $B_{ch} \leq a \therefore \in \text{Espacio de búsqueda}$ .

En la Figura 18 se presentan las muestras del conjunto\_1 utilizadas en el modelo de predicciones. Se observa la información de las 36 características las cuales cuentan con valores que van desde 5 a 30 Hz aproximadamente. También, se observa el atributo Sujetos

que permite identificar la información que fue recolectada por cada participante y el atributo Tarea que corresponde a la categorización o etiqueta de los datos.

Tabla 4 Conjuntos de datos construidos para analizar el comportamiento de la información

Conjunto	Características	No. Características
Conjunto_1	Delta_AF4, Delta_T8, Delta_AF3, Delta_F3, Delta_F7, Delta_F8, Delta_FC5, Delta_O2, Delta_P8, Alpha_AF4, Alpha_F3, Alpha_F7, Alpha_F8, Alpha_FC5, Alpha_O2, Alpha_P8, Alpha_T8, Beta_AF3, Beta_AF4, Beta_F3, Beta_F7, Beta_F8, Beta_FC5, Beta_O2, Beta_P8, Beta_T8, Gamma_AF4, Gamma_F3, Gamma_F7, Gamma_F8, Gamma_FC5, Gamma_O2, Gamma_P8, Gamma_T8	36
Conjunto_2	Alpha_AF4, Alpha_F3, Alpha_F7, Alpha_F8, Alpha_FC5, Alpha_O2, Alpha_P8, Alpha_T8	9
Conjunto_3	Beta_AF4, Beta_F3, Beta_F7, Beta_F8, Beta_FC5, Beta_O2, Beta_P8, Beta_T8, Gamma_AF4, Gamma_F3, Gamma_F7, Gamma_F8, Gamma_FC5, Gamma_O2, Gamma_P8, Gamma_T8	18
Conjunto_4	Alpha_AF4, Alpha_F3, Alpha_F7, Alpha_F8, Alpha_FC5, Alpha_O2, Alpha_P8, Alpha_T8, Beta_AF3, Beta_AF4, Beta_F3, Beta_F7, Beta_F8, Beta_FC5, Beta_O2, Beta_P8, Beta_T8,	18
Conjunto_5	Alpha_AF4, Alpha_F3, Alpha_F7, Alpha_F8, Alpha_FC5, Alpha_O2, Alpha_P8, Alpha_T8, Beta_AF3, Beta_AF4, Beta_F3, Beta_F7, Beta_F8, Beta_FC5, Beta_O2, Beta_P8, Beta_T8, Gamma_AF4, Gamma_F3, Gamma_F7, Gamma_F8, Gamma_FC5, Gamma_O2, Gamma_P8, Gamma_T8	27
Conjunto_6	Delta_AF4, Delta_T8, Delta_AF3, Delta_F3, Delta_F7, Delta_F8, Delta_FC5, Delta_O2, Delta_P8, Alpha_AF4, Alpha_F3, Alpha_F7, Alpha_F8, Alpha_FC5, Alpha_O2, Alpha_P8, Alpha_T8, Beta_AF3, Beta_AF4, Beta_F3, Beta_F7, Beta_F8, Beta_FC5, Beta_O2, Beta_P8, Beta_T8	27
Conjunto_7	Delta_AF4, Delta_T8, Delta_AF3, Delta_F3, Delta_F7, Delta_F8, Delta_FC5, Delta_O2, Delta_P8, Alpha_AF4, Alpha_F3, Alpha_F7, Alpha_F8, Alpha_FC5, Alpha_O2, Alpha_P8, Alpha_T8, Gamma_AF4, Gamma_F3, Gamma_F7, Gamma_F8, Gamma_FC5, Gamma_O2, Gamma_P8, Gamma_T8	27





Las configuraciones de los parámetros definidos en este trabajo se basan en el ajuste de múltiples rangos de valores propuestos en [122][148][149][150]. Fueron seleccionados aquellos parámetros con los que el modelo obtuvo mejores resultados durante la fase de entrenamiento como se observa en la Figura 19.

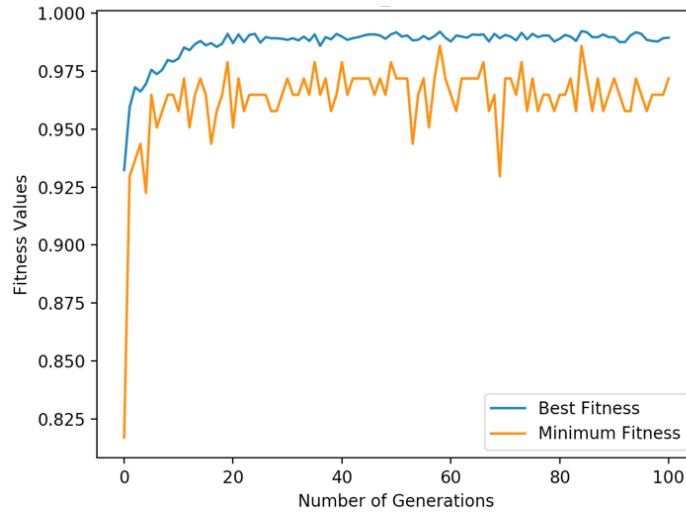


Figura 19 Análisis del desempeño de GALoR evaluando diferentes tamaños de poblaciones y generaciones.

Para GALoRSI, el número de generaciones definidas fueron 30, con un tamaño de población de 100 genes por generación. La configuración de la selección fue torneo de tamaño  $t = 5$  donde los individuos son "girados"  $t$  veces para buscar y seleccionar los cromosomas. El cruce de dos puntos se estableció con una probabilidad de corte de 0.8. La mutación fue simple con una probabilidad de 0.1.

Los parámetros de SVM fueron  $C = [0.0001, 1000]$  y  $\gamma = [0.00001, 10]$  y de  $k=[1,10]$ . GALoRSI se utilizó como estrategia de selección de los hiper parámetros para SVMRBF y k-NN. RL y SVMLineal se implementaron con una configuración básica.

## 4. RESULTADOS

### 4.1. Medidas Subjetivas

Los resultados obtenidos de las pruebas ISA y NASA-TLX durante el experimento son presentados en la Tabla 5. Los resultados obtenidos en la tarea\_2 fueron mayores que en la tarea\_1, concluyendo que los sujetos presentaron un aumento de carga cognitiva en la tarea\_2.

Tabla 5 Resultado de la prueba ISA y NASA-TLX

Sujetos	ISA		NASA-TLX	
	Tarea_1	Tarea_2	Tarea_1	Tarea_2
S1	16.66	34.44	4.33	65.67
S2	21.10	29.99	40	47.33
S3	31.10	57.77	12.67	56.67
S4	25.55	51.10	20.33	70.67
S5	21.10	43.33	64.33	68.67
Total	23.10	43.32	28.33	61.80

## 4.2. Medidas de Rendimiento Vehicular

En la Tabla 6 se presentan los resultados obtenidos en la prueba de TE durante el experimento donde los resultados de la Tarea\_2 fueron mayor que en la Tarea\_1. Estos resultados se interpretan como que los sujetos tuvieron una mayor tasa de error durante la Tarea\_2 debido al aumento de la carga cognitiva.

Tabla 6 Resultados de la prueba TE

Sujetos	Tarea_1	Tarea_2
S1	3	12
S2	7	3
S3	4	7
S4	3	8
S5	2	4
Total	19	34

## 4.3. Señales EEG

En la Tabla 7 se presenta un análisis descriptivo de cada una de las bandas de frecuencia extraídas de las señales EEG. Los resultados muestran que los valores de las bandas alfa, beta y gamma en Tarea\_2 fueron mayor que en la Tarea\_1. Así como, los valores de las bandas delta y theta aumentan durante la tarea\_1.

Estos resultados se deben al hecho de que cada banda está relacionada con un estado cognitivo como sugieren en [22][31][38][47][151]. Por ejemplo, en [38][39] observaron que la actividad de las ondas de las bandas delta [44] y theta [39] [152] fue mayor al desempeñar tareas relacionadas con la fatiga, cansancio o bajo rendimiento. Por otro lado, se observó en [22][40][41][42] que el incremento en la actividad de las ondas de las bandas alfa [40][153], beta [44] o gamma [151][154] fue mayor al realizar tareas relacionadas con el estado de estrés o sobrecarga de esfuerzo mental.

Tabla 7 Análisis Descriptivo de las señales EEG

Bandas	Tareas	Media	D.S.
Delta	Tarea_1	10.9193	1.20741
	Tarea_2	9.8171	0.5733
Theta	Tarea_1	10.2063	0.4682
	Tarea_2	9.9971	0.11242
Alfa	Tarea_1	10.4613	0.48171
	Tarea_2	10.6696	0.46037
Beta	Tarea_1	22.4447	0.89813
	Tarea_2	23.2951	0.3818
Gamma	Tarea_1	15.5624	0.19241
	Tarea_2	15.8033	0.16196

## 4.4. Resultados de la Prueba Estadística

La Tabla 8 muestra los resultados obtenidos de la prueba T-student donde se observan los valores de la media, la desviación estándar y el valor  $p$  de las muestras obtenidas durante la tarea\_1 y la tarea\_2. Los datos del sujeto\_2 fueron eliminados debido a que el sujeto presentó problemas de salud durante el experimento.



Los resultados estadísticos de ISA, muestran una diferencia significativa entre las dos tareas con un valor de  $p \leq 0.001$ , demostrando que los sujetos percibieron un incremento del nivel de carga cognitiva durante la tarea\_2 ( $M=46.6$ ,  $S=101.2$ ) que en la tarea\_1 ( $M=23.6$ ,  $S=38.1$ ,  $t(3)=-11.54$ ). En NASA-TLX los resultados fueron de  $p \leq 0.04$  donde los niveles de carga cognitiva fueron significativamente mayores en la tarea\_2 ( $M=65.4$ ,  $S=38.2$ ) que en la tarea\_1 ( $M=25.4$ ,  $S=715.7$ ,  $t(3) = -3.2$ ). En TE los resultados fueron de  $p \leq 0.02$  donde la tarea\_2 ( $M=8$ ,  $S=8$ ) fue significativamente mayor que la tarea\_1 ( $M=3$ ,  $S= 0.6$ ,  $t(3) = -3.9$ ).

Tabla 8 Resultados de la prueba T-Student

	Tarea_1	Tarea_2	p-value
	M±SD	M±SD	
NASA-TLX	25.41±715.7	65.42±38.25	$p \leq 0.048$
ISA	23.60±38.18	46.66±101.24	$p \leq 0.001$
TE	3±0.66	8.25±8.25	$p \leq 0.028$
DELTA	0.106±0.084	0.028±0.040	$p \leq .038$
THETA	0.056±0.032	0.041±0.007	$p \leq .383$
ALFA	0.074±0.033	0.088±0.032	$p \leq 0.05$
BETA	0.917±0.063	0.977±0.026	$p \leq .036$
GAMMA	0.432±0.013	0.449±0.011	$p \leq .005$

En las señales EEG se observó que las bandas alfa ( $M=-0.20$ ,  $SD=0.17$ ), beta ( $M=-.085$ ,  $SD=0.60$ ), delta ( $M=110.2$ ,  $SD=0.81$ ) y gamma ( $M=-0.24$ ,  $SD=0.09$ ) con valores de ( $p \leq 0.05$ ,  $t(4)= -2.656$ ), ( $p \leq 0.03$ ,  $t(4)= -3.119$ ), ( $p \leq 0.03$ ,  $t(4)= 3.041$ ) y ( $p \leq 0.005$ ,  $t(4)= -5.529$ ) demostraron una diferencia significativa entre las dos tareas donde la actividad de las bandas alfa, beta y gamma predominaron durante los periodos con alta carga cognitiva. Por otro lado, la banda delta obtuvo una mayor actividad en la señal en periodos con baja carga cognitiva. También, se observó que la banda theta ( $M=0.20$ ,  $SD=0.477$ ) con un valor de  $p \leq 0.383$  y  $t(4)= 0.980$  no mostró diferencias estadísticamente significativas.

La Tabla 9 presenta los resultados obtenidos al calcular el índice de correlación entre las medidas subjetivas, de rendimiento vehicular y las señales EEG.

Tabla 9 Resultados de la prueba de la correlación de Pearson en las medidas subjetivas, rendimiento vehicular y señales EEG

	Subjetivas		Desempeño	Señales EEG				
	ISA	NASA	TE	Alfa	Beta	Delta	Gamma	Theta
ISA	---							
NASA	0.598	---						
TE	0.612	0.538	---					
Alfa	0.301	-0.168	0.680	---				
Beta	0.488	-0.113	0.642	0.873	---			
Delta	-0.519	-0.097	-0.745	-0.830	-0.894	---		
Gamma	0.610	0.062	0.815	0.851	0.856	-0.805	---	
Theta	-0.121	0.206	-0.247	-0.592	-0.727	0.768	-0.329	---

ISA y TE presentaron una correlación media-alta con las bandas alfa ( $r_2 = 0.3$ ,  $r_2 = 0.6$ ), beta ( $r_2 = 0.4$ ,  $r_2 = 0.6$ ), delta ( $r_2 = -0.5$ ,  $r_2 = -0.7$ ), y gamma ( $r_2 = 0.6$ ,  $r_2 = 0.8$ ), sugiriendo una convergencia entre estas medidas, concluyendo que el comportamiento de la

información cambia paralelamente. Por otro lado, los resultados de NASA-TLX presentaron una correlación independiente con las señales EEG como en [36]. Esto puede deberse a que es una prueba de tipo post-ejercicio afectando el juicio del sujeto. Además, la banda theta demostró independencia en la correlación con las medidas subjetivas y de rendimiento vehicular.

#### 4.5. Técnica de Etiquetado

Los conjuntos de datos propuestos en la Tabla 4 fueron categorizados utilizando la técnica de etiquetado presentada en la Ecuación 27. Los resultados obtenidos para definir el rango de intervalo de los valores de carga cognitivos baja y alta son presentados en la Tabla 10.

En la Tabla 10 se observa el tamaño del rango de valores para categorizar la información de los siete conjuntos de datos. Por ejemplo, el subconjunto\_1 los rangos de intervalos obtenidos fueron  $Umbral_{[inferior]} = [0.0076, 0.0110)$  y  $Umbral_{[superior]} = [0.0110, 0.0176)$  esto se interpreta como los valores de entrada  $x$  que estén dentro de  $Umbral_{[inferior]}$  serán categorizados como 0 y los valores que estén dentro del rango  $Umbral_{[superior]}$  serán categorizados como 1.

En la Tabla 10 se observa que el rango del intervalo en los conjuntos de datos fue de  $x < 0.0110 \leq x$  en la mayoría de los casos.

Tabla 10 Intervalos de valores para categorizar los datos en los siete conjuntos de datos

Subconjuntos	Umbral Inferior	Umbral Superior
SC_1	$Umbral_{[inferior]} = [0.0076, 0.0110)$	$Umbral_{[superior]} = [0.0110, 0.0176)$
SC_2	$Umbral_{[inferior]} = [0.0049, 0.0084)$	$Umbral_{[superior]} = [0.0084, 0.0113)$
SC_3	$Umbral_{[inferior]} = [0.0036, 0.0110)$	$Umbral_{[superior]} = [0.0110, 0.0130)$
SC_4	$Umbral_{[inferior]} = [0.0043, 0.0110)$	$Umbral_{[superior]} = [0.0110, 0.0131)$
SC_5	$Umbral_{[inferior]} = [0.0072, 0.0110)$	$Umbral_{[superior]} = [0.0110, 0.0134)$
SC_6_1	$Umbral_{[inferior]} = [0.0026, 0.0110)$	$Umbral_{[superior]} = [0.0110, 0.0131)$
SC_6_2	$Umbral_{[inferior]} = [0.0018, 0.0110)$	$Umbral_{[superior]} = [0.0110, 0.0139)$
SC_6_3	$Umbral_{[inferior]} = [0.0013, 0.0110)$	$Umbral_{[superior]} = [0.0110, 0.0135)$
SC_6_4	$Umbral_{[inferior]} = [0.0046, 0.0110)$	$Umbral_{[superior]} = [0.0110, 0.0129)$
SC_7	$Umbral_{[inferior]} = [0.0084, 0.0110)$	$Umbral_{[superior]} = [0.0110, 0.0133)$

#### 4.6. Resultados de GALoRSI

La Tabla 11 muestra los resultados obtenidos de GALoRSI. Se observa, que con el método propuesto en esta investigación se reduce en promedio el número de atributos de 36 a 13 características analizando el primer conjunto de datos, representando un 64% menos de los datos originales. Al reducir la dimensionalidad del conjunto de datos original permite generar modelos más eficientes e ideales en aplicaciones en tiempo real.

El subconjunto\_1 obtuvo un rendimiento de exactitud del 97% donde 13 características se identificaron con información relevante. El subconjunto\_2 logró un rendimiento de

exactitud del 77% con 3 características seleccionadas. El subconjunto\_3 obtuvo una exactitud del 88% con 11 características seleccionadas. El subconjunto\_4 logró un rendimiento de exactitud del 94% identificando 16 características con información relevante. El subconjunto\_5 identificó 17 características, obteniendo un rendimiento de exactitud del 95%. El subconjunto\_6 identificó cuatro diferentes combinaciones de datos con un rendimiento de exactitud del 96% en cada uno. Los cuatro subconjuntos identificaron 8, 10, 13 y 18 características. Finalmente, el subconjunto\_7 logró un 90% seleccionando 19 características.

Además, la Tabla 11 muestra los cromosomas generados en cada conjunto de datos, donde cada elemento del vector es un gen del cromosoma ( $Cr$ ) que representa las características que fueron seleccionadas. Por ejemplo, en el subconjunto\_1 el individuo creado por GALoRSI es

$$Cro = [0, 1, 1, 1, 0, 0, 0, 1, 0, 1, 1, 1, 1, 0, 0, 0, 1, 1, 0, 0, 0, 1, 0, 0, 0, 1, 0, 0, 0, 0, 1, 0, 0, 0, 0, 0]$$

donde  $x_i = 1 \therefore \in Cor'$  es definido como

$$Cro' = [x_2, x_3, x_4, x_8, x_{10}, x_{11}, x_{12}, x_{13}, x_{17}, x_{18}, x_{22}, x_{26}]$$

Cada  $x_i = 1$  del vector corresponde a un elemento que describe una característica del subconjunto\_1, creando el nuevo cromosoma con 13 características seleccionadas como se muestra a continuación

$$Cro' = [\text{DELTA}_{AF4}, \text{DELTA}_{F3}, \text{DELTA}_{F7}, \text{DELTA}_{P8}, \text{ALPHA}_{AF3}, \text{ALPHA}_{AF4}, \text{ALPHA}_{F3}, \text{ALPHA}_{F7}, \text{ALPHA}_{P8}, \text{ALPHA}_{T8}, \text{BETA}_{F7}, \text{BETA}_{P8}, \text{GAMMA}_{F7}]$$

Además, en la Tabla 11 se observa que la mayoría de los atributos propuestos en el subconjunto\_4 fueron seleccionados, demostrando que la combinación de la banda alfa y beta pueden identificar los estados cognitivos.

Las características con alta tasa de selección fueron Delta\_F7 ( $p=1.29E-27$ ), Alfa\_AF4 ( $p=4.14E-26$ ), Alfa\_F3 ( $p=5.80E-05$ ), Alfa\_F7 ( $p=5.50E-16$ ), Alfa\_F8 ( $p=6.03E-22$ ), Alfa\_O2 ( $p=9.14E-09$ ), Alfa\_P8 ( $p=1.76E-15$ ), Beta\_AF4 ( $p=3.38E-13$ ) y Beta\_FC5 ( $p=4.19E-24$ ) demostrando tener información relevante que puede usarse para identificar diferentes estados cognitivos. Por otro lado, las características con menos tasa de selección fueron Delta\_T8 ( $p=0.292$ ), Alfa\_T8 ( $p=0.518$ ), Gamma\_AF3 ( $p=0.407$ ), Gamma\_AF4 ( $p=0.501$ ), Gamma\_FC5 ( $p=0.677$ ), Gamma\_O2 ( $p=0.517$ ), Gamma\_T8 ( $p=0.887$ ).

El tiempo de ejecución promedio de GALoRSI fue de 516.867s esto es debido a que las señales EEG son categorizadas por su alta dimensionalidad incrementando directamente la complejidad computacional al estructurar los datos, seleccionar características y clasificar los datos [151].



En general, el subconjunto\_6\_1 obtuvo el mejor desempeño en los cuatro clasificadores, con una precisión del 94.68%, seguido por el subconjunto\_4 con 94.37%, el subconjunto\_5 obtuvo el 93.28%, el subconjunto\_1 con el 93.23%, el subconjunto\_7 logró el 92.85%, el subconjunto\_6\_2 con el 92.01%, el subconjunto\_6\_3 obtuvo el 91.06%, subset\_3 con 90.43%, subset\_6\_4 con 88.05% y finalmente subset\_2 logró 74.23%. Estos resultados pueden deberse a los criterios establecidos para formar los siete conjuntos de datos, concluyendo que al combinar la información proveniente de diversas bandas se obtienen mejores resultados construyendo modelos con juicios más confiables.

Tabla 12 Resultados obtenidos con los clasificadores SVMRBF, SVMLineal, k-NN y LR

Subset	SVMRBF			k-NN			SVMLINEAL			LR		
	Entr	Prue	Sens	Entr	Prue	Sens	Entr	Prue	Sens	Entr	Prue	Sens
SC_1	96.77	96.71	96.64	97.67	97.50	97.50	89.38	89.29	89.36	89.57	89.43	89.46
SC_2	85.50	84.36	84.34	82.59	81.66	81.89	66.03	65.97	65.92	65.02	64.96	64.94
SC_3	97.61	97.02	97.00	94.91	94.26	94.38	85.60	85.57	85.53	85.02	84.87	84.92
SC_4	98.27	98.16	98.08	98.70	98.50	98.50	91.02	90.73	90.68	90.25	90.09	90.06
SC_5	97.70	97.27	97.28	97.61	97.46	97.42	89.66	89.50	89.40	89.06	88.91	88.89
SC_6_1	98.38	98.24	98.28	98.76	98.64	98.60	91.39	91.27	91.18	90.79	90.59	90.78
SC_6_2	96.75	96.54	96.57	98.40	98.17	98.20	86.90	86.86	86.80	86.52	86.47	86.38
SC_6_3	98.54	98.27	98.27	97.28	96.90	96.98	84.71	84.64	84.49	84.58	84.45	84.43
SC_6_4	97.97	97.72	97.67	95.38	95.03	94.84	79.97	79.96	79.90	79.59	79.50	79.51
SC_7	97.55	97.17	97.14	96.73	96.50	96.35	85.08	84.94	84.78	92.95	92.82	92.80
Total	96.50	96.14	96.64	95.80	95.46	95.47	84.97	84.87	84.80	85.33	85.21	85.21

## 5. DISCUSIONES Y CONCLUSIONES

Los resultados obtenidos de GALoRSI fueron comparados con los métodos de selección de características de la información mutua (MI- Mutual Information) y el análisis de componentes principales (PCA- Principal Component Analysis) más utilizados en la literatura para analizar señales de EEG [155]. Los algoritmos fueron evaluados utilizando los siete conjuntos de datos propuestos en esta investigación y en la Tabla 13 se presentan los resultados.

Tabla 13 Resultados del desempeño de los cuatro clasificadores que utilizan los algoritmos GALoRSI, Información Mutua (MI) y Análisis de Componentes Principales (PCA).

SubConj.	GALoRSI				MI				PCA			
	SVM RBF	k-NN	SVM	LR	SVM RBF	k-NN	SVM	LR	SVM RBF	k-NN	SVM	LR
SC_1	96.77	97.50	89.29	89.43	87.78	86.87	76.37	77.40	80.48	80.08	69.03	68.78
SC_2	84.36	81.66	65.97	64.96	98.78	98.17	98.32	97.65	98.66	99.33	98.62	98.72
SC_3	97.02	94.26	85.57	84.87	88.00	86.87	76.37	77.40	86.05	85.38	83.46	83.43
SC_4	98.16	98.50	90.73	90.09	84.65	81.21	78.47	76.85	79.38	78.19	60.44	61.26
SC_5	97.70	97.46	89.50	88.91	87.78	86.87	76.37	77.40	76.33	75.06	62.39	62.08
SC_6	97.91	97.18	85.68	85.25	87.08	85.26	78.68	77.43	83.16	82.42	68.17	67.75
SC_7	97.17	96.50	84.94	92.82	85.53	82.06	76.40	76.12	79.59	79.26	65.89	65.46
Total	96.14	95.46	84.87	85.21	88.51	86.76	80.14	80.04	83.38	82.82	72.57	72.50

Como se observa en la tabla, GALoRSI obtuvo los mejores resultados de rendimiento, logrando un promedio total en los cuatro clasificadores del 90.42% de precisión, seguido de MI con 83.86% y PCA con 77.81% donde GALoRSI-SVMRBF obtuvo los mejores

resultados con un 96.14%. También, se observó que el desempeño de GALoRSI es mejor al trabajar con grandes conjuntos de datos en comparación con los otros algoritmos, por ejemplo, el conjunto\_1 conformado por 36 características logró una tasa de precisión del 96%. Por otro lado, los algoritmos MI y PCA obtuvieron mejores resultados al trabajar con conjuntos de datos de menor tamaño, como se observó en los resultados obtenidos en el conjunto\_2. Cuando se trabaja con señales EEG, es importante considerar el volumen de los datos y que este aumentará dependiendo del tipo de experimento, los estados por analizar (emocionales, cognitivos o enfermedades), el tipo de sensor y los electrodos que lo integran.

En la Figura 20, se presentan una comparativa de investigaciones relacionadas a este trabajo enfocadas en el desarrollo de modelos capaces de identificar patrones en la información extraída de las señales EEG para describir el comportamiento interno del sujeto con la mayor exactitud posible. En [156] exploró un método de extracción de características y clasificación de la información basado en la entropía del ritmo y SVM utilizando las señales EEG. El modelo logró un 89.7% de precisión. En [112] proponer un modelo de selección y clasificación de datos EEG utilizando GA y SVM. El modelo obtiene en promedio un 91%. En [157] proponen un modelo para el reconocimiento de patrones basado en las señales EEG utilizando el algoritmo de la máquina de aprendizaje gráfico extremo regularizado. El algoritmo logra un 69.67% y 91.07% de precisión. En [45] proponen un modelo para seleccionar y clasificar características basado en el algoritmo de información parcial mutua y análisis de discriminación lineal utilizando señales EEG. El algoritmo obtuvo un 88.7% de precisión. En [85] desarrollaron un modelo para extraer las características más relevantes de las señales EEG y clasificar la información utilizando el algoritmo causalidad de Granger y SVM obteniendo un resultado de precisión del 82.66%. En [158] proponen un sistema de clasificación de emociones basado en la señal EEG utilizando medidas estadísticas y KNN. El sistema logró una precisión del 86.12% en promedio. En [159] propone un sistema para la detección del estado de estrés mediante un algoritmo genético y k-NN basado en señales de EEG logrando una precisión del 71.76%. En [160] presentan un sistema para encontrar las características más relevantes y clasificar la señal EEG utilizando algoritmo genético y SVM. El sistema logró una precisión del 94.4%. En [161] proponen un algoritmo para clasificar imágenes motoras de señales EEG basado en algoritmos genéticos y análisis de componentes de vecinos regularizados para mejorar el rendimiento del clasificador. El algoritmo logró una precisión del 78.9%. En [53] proponen un clasificador basado en señales EEG para el reconocimiento del estado de depresión utilizando algoritmos genéticos, SVM, k-NN y árboles de decisión, logrando una tasa de precisión del 86.98%. En [162] presentan un algoritmo de selección de características de las señales EEG relacionadas con imágenes motoras utilizando los algoritmos genéticos logrando una precisión del 76.04%. GALoRSI-SVM obtiene una precisión del 96.14% en la clasificación de los datos, mejorando significativamente el rendimiento del clasificador.




Figura 20 Comparación de resultados obtenidos con otros algoritmos parecidos a GALoRSI-SVM en la literatura

En este capítulo, introducimos un nuevo modelo para el reconocimiento de patrones llamado GALoRSI que combina la capacidad de los algoritmos genéticos para resolver problemas complejos, con la efectividad y simplicidad del algoritmo de regresión logística.

Los resultados de este capítulo demostraron varios aspectos. Primero, las medidas propuestas en esta investigación permiten evaluar el nivel de carga cognitiva de los sujetos mientras realizan la tarea de la conducción de un vehículo. Segundo, las pruebas estadísticas demostraron una relación entre las medidas subjetivas, de desempeño vehicular y fisiológicas con los estados cognitivos, permitiendo analizar el comportamiento interno y externo del sujeto durante el experimento. Con ello se observó, que a medida que aumentaba la dificultad en la tarea, los conductores mostraron un aumento en la demanda de la carga cognitiva, afectando su concentración y aumentando los errores durante la conducción. Tercero, en este capítulo se propuso un enfoque de fusión de datos para construir diversos conjuntos de datos con el objetivo de analizar el comportamiento de los datos. Se observó una mejora del 20% en el rendimiento del modelo al compararlo con un modelo construido utilizando múltiples fuentes de datos como es el caso de subconjunto\_6\_1 y el modelo construido con información proveniente de una sola fuente como es el caso del subconjunto\_2.

Por último, se presentó el modelo GALoRSI como una nueva estrategia de búsqueda para explorar de manera más eficiente la información de las señales EEG e identificar las características que describen los estados de baja y alta carga cognitiva. Los resultados de GALoRSI muestran que los algoritmos de selección de características para el reconocimiento de patrones son fundamentales para obtener un mejor desempeño en los modelos de predicción. Además, se observó que GALoRSI-SVMRBF es capaz de soportar conjuntos de datos de diversos tamaños, reduciendo el 64% del conjunto de datos original y a su vez maximizando la capacidad predictiva en los modelos de predicción, logrando una precisión del hasta el 98% en la clasificación de la información.

Aunque el tiempo promedio de procesamiento de GALoRSI fue de 516.867s se encuentra dentro del tiempo promedio obtenido en los modelos [39][88][93][163].

Es fundamental considerar que la selección de características es un procedimiento que se realiza una vez y no afecta el tiempo de prueba del modelo. Se observó que el tiempo de procesamiento durante la fase de prueba se redujo en un 80% permitiendo utilizar el modelo en sistemas de tiempo real que proporcionan rápidos tiempos de respuesta.





## CAPÍTULO V

### TERCERA FASE DEL DESARROLLO DEL MODELO DE PREDICCIONES: VALIDACIÓN DEL MODELO DE PREDICCIONES DE ESTADOS COGNITIVOS

En este capítulo, se presenta la fase de validación del modelo de predicciones denominado GALoRSI-SVMRBF utilizando la base de datos internacional SEED-VIG [154]. GALoRSI-SVMRBF fue diseñado, centrándose en la selección de las características, estructuración de la información y construcción de un clasificador con el objetivo de crear un sistema capaz de modelar datos multidimensionales de las señales EEG y obtener predicciones más exactas.

Para evaluar la capacidad de adaptación del modelo a nuevos conjuntos de datos y analizar la capacidad predictiva del modelo, fue utilizada la base de datos internacional de señales EEG SEED-VIG para evaluar el comportamiento de GALoRSI-SVMRBF. SEED-VIG se ha implementado en una serie de estudios relacionados con la conducción de vehículos analizando estados emocionales para evaluar nuevos modelos desarrollados.

La información de este capítulo fue utilizada para la publicación del artículo titulado “Emotion Recognition Model based on Genetic Algorithms, Logistic Regression and Vector Support Machines using EEG Signals”.

#### 1. INTRODUCCIÓN

Las personas realizan diariamente actividades que involucran la interacción Máquina-Sujeto llegando a ser una tarea compleja, multifacética y potencialmente riesgosa. Para mejorar esta experiencia, se han propuesto sistemas que evalúan los recursos cognitivos, mentales y emocionales de las personas al realizar tareas que involucran máquinas con el principal objetivo de evitar accidentes.

En los recientes años, se han utilizado las señales fisiológicas para analizar el desempeño del sujeto, enfatizando particularmente en el uso de las señales EEG. Las señales EEG son recolectadas directamente del sistema nervioso central, proporcionando información directa del estado interno del sujeto [97].

En general, las señales EEG son analizadas con algoritmos computacionales para generar modelos capaces de detectar y predecir el estado del sujeto, sin embargo, uno de los principales problemas a los que se enfrentan estos modelos es que no existe un conjunto de características EEG establecidas para el reconocimiento y/o detección de un estado

específico del sujeto debido a la alta dimensionalidad de la señal [115]. Esto incrementa el tiempo de análisis y procesamiento de la información afectando el desempeño del modelo.

En la literatura, se proponen diversos modelos de predicciones que se enfocan principalmente en el análisis de la información EEG para identificar elementos que tengan un impacto significativo a la hora de describir una emoción o estado de la persona. A continuación, se presentan algunos modelos desarrollados de los últimos tres años. En [97] presentan un modelo para predecir estados emocionales introduciendo un nuevo sistema que busca un subconjunto de características EEG utilizando cinco algoritmos evolutivos computacionales (optimización de colonias de hormigas (ACO- Ant colony optimization), recocido simulado (SA- Simulated annealing), algoritmo genético (GA- Genetic algorithm), optimización de enjambre de partículas (PSO- Particle swarm optimization), evolución diferencial (DE- Differential evolution)) y el algoritmo de red neuronal probabilística (PNN- probabilistic neural network) para identificar y clasificar la información EEG como se muestra en la Figura 21.

Para el desarrollo del modelo, se propone una nueva base de datos experimental que contiene 5 canales y además utilizan las bases de datos públicas DEAP y MAHNOB de 32\*45 (canales \*características) dimensiones cada una para evaluar el modelo. Los resultados de precisión al clasificar los datos fueron de 67.47%, 96.97% y 65.04% en las bases de datos experimental, DEAP y MAHNOB. Este modelo obtuvo varios problemas en secuencia. El primer problema fue que los algoritmos evolutivos presentaron una convergencia prematura. Para enfrentar este problema, incrementaron la tasa de entrenamiento de los algoritmos logrando estabilizar la tasa de rendimiento. Sin embargo, esta acción repercutió en el coste computacional incrementando de minutos a 82.88h el tiempo de procesamiento. Para resolver este problema, seleccionaron de manera empírica un subconjunto de datos reduciendo la información de 1440 a 30 características para maximizar el rendimiento del clasificador, logrando reducir el costo computacional. La técnica de selección de la información descarta datos EEG relevantes del modelo.

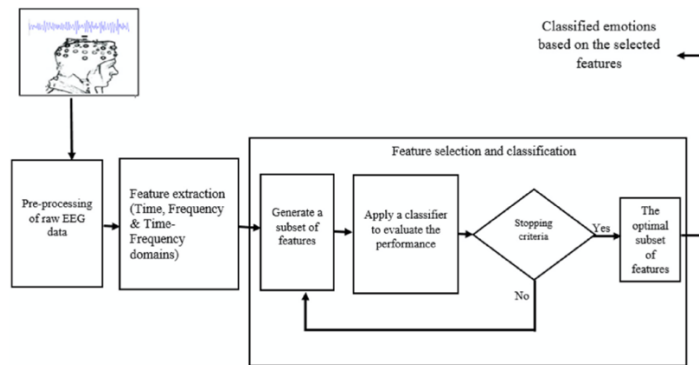


Figura 21 Modelo de predicción de estados emocionales basado en algoritmos evolutivos computacionales y PNN.

En [161] proponen un modelo para predecir estados emocionales basado en el algoritmo de análisis de competencia entre vecinos (RNCA- Regularized NCA neighbourhood component analysis) y SVM para seleccionar y clasificar la información EEG como se observa en la Figura 22. RNCASVM utiliza la información de las bandas de frecuencia beta

y mu para calcular la ponderación del peso de cada banda por medio de una función objetivo. También, implementaron un parámetro de regularización de la tasa de error para controlar el sobreajuste de los datos. El modelo redujo el conjunto de datos de 42 a 7 características obteniendo una tasa de precisión del 80%.

RNCASVM no utiliza técnicas para el análisis y procesamiento de la señal. Así como, limita el número de datos de entrada debido a que la implementación de grandes volúmenes de datos degrada el rendimiento del modelo.



Figura 22 Diagrama de la técnica de selección de características RNCA

En [164] presenta un modelo para clasificar imágenes motoras de las señales EEG basado en un método de selección de características definido como mecanismo de reducción de la dimensionalidad (DimReM - Dimensionality Reduction Mechanism) como se muestra en la Figura 23. DimReM implementa algoritmos evolutivos (GA, PSO-Binario y evolución diferencial (DE-differential evolution)), SVM, k-NN y análisis de discriminación (DA-Discriminant Analysis) para seleccionar y clasificar la información. Además, utiliza dos bases de datos públicas de 288 y 384 características para analizar los rangos de frecuencias de 4–36 Hz y 8–32 Hz. El modelo logró una tasa de precisión del 94.28% reduciendo el conjunto de datos a 114, 124, y 105 características.

La principal función de DimReM es identificar y eliminar las características menos importantes durante el proceso evolutivo. DimReM genera una población donde los elementos no seleccionados, son considerados no relevantes y son eliminados desde la primera etapa evolutiva. Este método tiene dos principales desventajas. La primera desventaja es que descarta características relevantes cuando estas son evaluadas individualmente. La segunda desventaja es que al implementar bases de datos con un número limitado de características se puede producir una convergencia prematura.

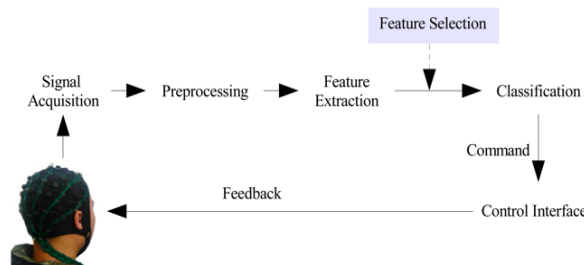


Figura 23 Mecanismo para reducir la dimensionalidad del conjunto de datos de las señales EEG

En este capítulo, se presenta el modelo de predicción definido como GALoRSI-SVMRBF (Genetic Algorithms and Logistic Regression for the Structuring of Information -Support

Vector Machine with Radial Basis Function Kernel) basado en las señales EEG. GALoRSI-SVMRBF es un modelo enfocado en la selección, estructuración y clasificación de las señales EEG que integra tres poderosos algoritmos (algoritmos genéticos (GA), regresión logística (RLo) y máquinas de soporte vectorial (SVM)) para optimizar el proceso de modelado y clasificación de los datos, obteniendo un mejor desempeño con una alta tasa de predicción que permite afrontar el principal problema de las señales EEG, su alta dimensionalidad [115].

GALoRSI-SVMRBF inicia el proceso seleccionando un conjunto de datos por medio del algoritmo genético (AG), los cuales, son analizados dentro de una función de ajuste basada en el algoritmo de regresión logística (RLo) con el objetivo de evaluar de manera individual y grupal los elementos, direccionando la busca a nuevos datos con mejores características capaces de describir un evento o resolver un problema, evitando procesos multidireccionales en paralelo con un alto costo computacional y una convergencia prematura. Los elementos seleccionados son utilizados para estructurar una nueva base de datos multidimensional basada principalmente en la calidad y en la coherencia de los datos permitiendo optimizar el proceso de entrenamiento y aprendizaje del modelo de predicciones.

Para analizar GALoRSI-SVMRBF se utilizó la base de datos pública SEED-VIG (SJTU Emotion EEG Dataset) propuesta en [154]. La base de datos fue implementada como datos de entrada para evaluar la capacidad de adaptación del modelo a nuevos conjuntos de datos. SEED-VIG es una base de datos creada para examinar la experiencia de los sujetos durante la conducción de un vehículo en un entorno simulado. SEED-VIG ha sido implementada en una serie de estudios con el propósito de evaluar nuevos modelos [157].

Las principales contribuciones de este capítulo pueden estar resumidas como: 1) se presenta la metodología del desarrollo de un modelo para el reconocimiento de dos estados cognitivos basado en algoritmos genéticos, regresión logística y máquinas de soporte de vectores utilizando señales EEG. 1.1) Se desarrollaron dos técnicas de validación del modelo: interna y externa. 1.2) La técnica de validación interna fue desarrollada utilizando métricas de desempeño. 1.3) La técnica de validación externa analiza y compara los resultados de otras investigaciones que implementan la misma base de datos. 1.4) Se implementan múltiples algoritmos para analizar y comparar los resultados del modelo. 2) GALoRSI-SVMRBF es capaz de soportar y adaptarse a conjuntos de datos multidimensionales de señales EEG. 2.1) Se presenta una nueva técnica para estructurar datos multidimensionales utilizando la información de una base de datos internacional de señales EEG.

Este capítulo está organizado de la siguiente manera. En la sección 2 se describe el algoritmo desarrollado. La sección 3 presenta la base de datos utilizada en esta investigación. Los resultados obtenidos se explican en la sección 4. Finalmente, las conclusiones y discusiones son presentadas en la sección 5.

## 2. GALORSI-SVMRBF

En la Tabla 14 se presenta el modelo GALoRSI-SVMRBF el cual inicia seleccionando un conjunto de elementos de la base de datos para construir un cromosoma. El cromosoma generado, es evaluado en una función de ajuste donde se construye un modelo RLo basado

en los elementos del cromosoma. El modelo RLo, es analizado utilizando los parámetros denominados números de adaptación ( $NA$ ), los cuales, ayudarán a evaluar de manera grupal e individual los elementos del cromosoma. Los  $NA$  son: tasa de ajuste entre elementos, tasa de error, número de elementos y elemento significativo. Cada cromosoma es almacenado en una lista junto con los valores obtenidos de cada parámetro donde el cromosoma con una alta tasa de ajuste, baja tasa de error y menor número de elementos tendrá una alta prioridad y será colocado al principio de la lista. Esto permite que los cromosomas con mejores características tengan mayor probabilidad de continuar en el proceso evolutivo.

Una vez ordenada la lista, los elementos son utilizados para iniciar el proceso de reproducción donde los cromosomas de la lista son seleccionados en orden secuencial para intercambiar sus genes y generar nuevos descendientes. Después, es introducido un determinado grado de mutación sobre el primer elemento del nuevo cromosoma con el objetivo de generar diversidad en la población y finalmente se vuelven a evaluar los cromosomas en la función de ajuste para seleccionar los mejores cromosomas y heredarlos en la siguiente generación.

Los elementos más significativos de la generación son unidos en un vector para construir un nuevo cromosoma con mejores propiedades y heredarlos a la siguiente generación, evitando búsquedas multidireccionales en paralelo y direccionando la búsqueda de los nuevos elementos que integrarán un nuevo cromosoma. El proceso evolutivo continúa iterando  $n$  generaciones obteniendo  $Generaciones * Cromosomas$  posibles soluciones y finalizará cuando se cumpla una de las dos normas de detección establecidas. Estas normas son: número máximo de iteraciones o se han obtenido el valor máximo definido en los  $NA$  (tasa de ajuste =1; tasa de error=0).

Una vez finalizado el proceso de selección de características, es estructurado el nuevo conjunto de datos basado en el cromosoma obtenido. Este proceso consiste en comparar el cromosoma generado con las características de la base de datos original para seleccionar aquellos elementos del cromosoma y construir un nuevo conjunto de datos. En la Ecuación 29 se presenta la estructura general para construir el nuevo conjunto de datos

$$GALoR = \{cromosoma\} \therefore \in \text{Nuevo conjunto datos} \{x_i y_i\}_{i=1}^N$$

Donde

$$x_i = [Banda1_{ch11, ch12, \dots, ch1n}, Banda2_{ch21, ch22, \dots, ch2n}, BandaX_{chm1, chm2, \dots, chmn}]$$

$$y_i = [0|1]$$

Ecuación 29

$x_i$  contiene la información de las señales EEG organizadas de menor a mayor siguiendo el orden del rango de frecuencias. Esta estructura permite construir bases de datos con la información de uno o múltiples canales enfrentando el principal problema de las señales EEG, su alta dimensionalidad.

Por último, los datos son introducidos en el clasificador SVMRBF para entrenar y evaluar al modelo. El clasificador SVMRBF es desarrollado en tres etapas. La primera etapa, consiste en el preprocesamiento de la información donde los datos son divididos en dos grupos: entrenamiento y prueba donde el 90% de las muestras son destinadas para entrenar el modelo y el 10% restante es utilizado para realizar las pruebas del modelo entrenado. Fue utilizada la técnica de validación cruzada  $k$ -fold ( $k=5$ ) para evaluar el rendimiento del clasificador y prevenir problemas de sobreajuste en el modelo.

La segunda etapa consiste en construir el clasificador SVMRBF utilizando el conjunto de datos de entrenamiento. Esta etapa consiste en tomar los datos de entrada como  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  y mapearlos a un espacio de características de mayor dimensión, es decir, si los datos de entrada están en  $\mathcal{R}^2$  los mapea en  $\mathcal{R}^3$  [165]. Después, SVM utiliza la función de kernel para encontrar el hiperplano de separación óptimo que mejor maximice la clasificación de los datos como se describe en la Ecuación 30

$$f(x) = \sum_{i=1}^l \alpha_i K(x, x_i) + b$$

Ecuación 30

donde  $\alpha_i$  son los datos de entrada,  $b$  es la constante de la variable y  $K(x, x_i)$  es la función del kernel. En esta investigación, fue implementado el kernel tipo RBF debido a que es capaz de clasificar datos de alta dimensión con un menor número de parámetros, reduciendo su nivel de complejidad [166]. Para encontrar la mejor configuración de los parámetros de penalización  $C$  y gamma  $\gamma$  de RBF fue implementado el proceso evolutivo de GALoRSI.

La última fase del clasificador consiste en evaluar el modelo creado y entrenado, utilizando el conjunto de datos de prueba. Además, son implementadas las métricas de exactitud, sensibilidad y precisión utilizadas para analizar el desempeño de los modelos de predicción.

### 3. SEED-VIG

SEED-VIG propuesto por primera vez en [73] contiene la información de las señales EEG recolectadas de 21 sujetos (12 hombres y 9 mujeres) de entre 20 y 25 años de edad mientras realizaban la conducción de un vehículo en un entorno simulado como se muestra en Figura 24.

Antes de iniciar cada experimento, los participantes realizaron una sesión de prueba para familiarizarse con las herramientas y aparatos del experimento. Se le solicitó a cada participante que condujera el automóvil durante 2 horas en el entorno de conducción simulado donde fueron mostrados 15 videos con una duración de 4 minutos cada video para evaluar tres clases de emociones: positivas, neutrales, negativas. Todos los experimentos se realizaron de 13:00-15:00 p.m. y de 21:00 p.m. a 23:00 p.m.

Tabla 14 Algoritmo de modelo de predicciones GALoRSI-SVMRBF

**Entrada:** población (**Cromosoma**[ $BandaX_{chm1, chm2, \dots, chmn}$ ])  
Inicialización de la población:  
 $K := 0$   
 $P_k$  : = Crear los cromosomas de la población  
Número de generaciones  $gen$   
Evaluar  $P_k$ :  
**do**  
  **for**(( $P_k$ .length)-1)  
    *Crear generación  $k+1$ :*  
      Seleccionar  $n$  miembro de  $P_k$  e insertar en  $Ch_k$ ;  
      *Función de Ajuste  $Ch_k$*   
        Calcular **Función de Ajuste** ( $Ch_{k[PA]}$ ) por cada  $Ch_k$  y  $n$  con RL;  
        Evaluar **Función de Ajuste**( $n_1, n_2, n_3, \dots, n_x, PA_{EX} \cdot PA_{TE} \cdot PA_{NE} \cdot PA_{ES}$ )  
      *Selección*  
      Seleccionar y guardar el mejor  $Ch_k = [Channel_1, Channel_2, \dots, Channel_i, PA_{EX} \cdot PA_{TE} \cdot PA_{NE} \cdot PA_{ES}]^T$   
      donde  $Ch_{k+1}$   
      mientras ( $Ch_k \neq 0$ )  
      **if**  $Ch_k = [ > PA_{EX} | < PA_{TE} | < PA_{NE}]$  insertar  
       $Ch_{k++1}$   
      *Cruce*  
      Seleccionar  $\mu * n$  miembros de cada  $Ch_k$ ;  
      Realizar el cruce;  
      Producir descendencia;  
      Insertar la descendencia en  $Ch_{k+1}$ ;  
      *Mutación*  
      Seleccionar  $\mu * n$  miembros de  $Ch_{k+1}$ ;  
      Invertir el valor del elemento seleccionado;  
      *Función de Ajuste  $Ch_k$*   
      *Seleccionar*  
      *Incrementar*  
      Número de generaciones incrementa  $k := k + 1$   
      Hasta  $k=gen$   
Hasta encontrar una cromosoma con los valores de  $P_k [ > PA_{EX} | < PA_{TE} ]$  o cumplir el número de  $k=gen$   
Devolver el cromosoma  $P_k$  con  $Ch_k = [Channel_1, Channel_2, \dots, Channel_i, PA_{EX} \cdot PA_{TE} \cdot PA_{NE} \cdot PA_{ES}]$   
**Construir la estructura de la nueva base de datos**  
**GALoR** =  $\{Ch_k\} \therefore \in New Dataset \{x_i y_i\}$   
**Clasificador**  
  *Fase 1*  
   $\{x_i y_i\}$  con  $k - fold CV = \{Entrenar_x; Prueba_t\}$   
  *Fase 2*  
  Construir el modelo SVMRBF  
  GALoRSI: población (**Features**)  
  Conjunto de datos **Entrenar<sub>x</sub>**  
  *Fase 3*  
  Evaluando el modelo con el **Prueba<sub>t</sub>** conjunto de datos y actuaciones  
Métricas **{Exactitud; Sensibilidad; Exactitud}**






Figura 24 Fase de experimentación de SEED a) simulación de la conducción, b) participante portando los sensores para la recolección de la información EEG y EOG, c) experimentación en curso [167]

Las señales EEG fueron registradas utilizando el sistema ESI NeuroScan de 62 electrodos con una frecuencia de muestreo de 1000Hz. Simultáneamente, fueron recolectados los datos del movimiento ocular EOG (Electrooculograma) utilizando las gafas SMI ETG como referencia para identificar el estado emocional del sujeto e implementaron la técnica de PERCLOS propuesto en [154] para calcular tres índices de emociones que sirvieron para categorizar los datos de las señales EEG como se presenta en la Ecuación 31

$$Rangos \begin{cases} x \leq 0.35 & \text{emoción positiva 0} \\ 0.35 < x < 0.7 & \text{emoción neutral 2} \\ x \geq 0.7 & \text{emoción negativa 1} \end{cases}$$

Ecuación 31

$x$  son los datos de las señales EEG donde si su valor es menor a 0.35 los datos se clasifican como una emoción positiva correspondiente a una etiqueta 0. Si su valor va de entre 0.35 y 0.7 los datos se clasifican como una emoción neutral correspondiente a una etiqueta 2. Si el valor es mayor a 0.7, los datos se clasifican como una emoción negativa correspondiente a una etiqueta 1. En esta investigación, fueron analizadas las muestras de las emociones positivas y negativas de SEED-VIG para mantener la coherencia en el análisis desarrollado en esta investigación.

### 3.1. Procesamiento y Estructuración de SEED-VIG

Para analizar el conjunto de datos de SEED, fue utilizada la versión pre-procesada de PSD propuesta en [168] que contiene la información de cinco bandas de frecuencia: delta (1–4 Hz), theta (4–8 Hz), alfa (8–14 Hz), beta (14–31 Hz) y gamma (31–50 Hz). Los datos fueron normalizados en un rango de [0-1].

En [154] proponen una técnica para estructurar los datos de SEED-VIG. En esta investigación, fue utilizado el método de estructuración de la información que se presenta en la Ecuación 32.

$$ConjuntoDatos = [Delta_{ch_1, \dots, ch_n}, Theta_{ch_1, \dots, ch_n}, Alfa_{ch_1, \dots, ch_n}, Beta_{ch_1, \dots, ch_n}, Gamma_{ch_1, \dots, ch_n}]^M$$

Ecuación 32

donde los datos fueron organizados siguiendo el orden de las bandas de frecuencia (delta, theta, alfa, beta y gamma) y  $ch_n$  es la información de los 17 canales utilizados en SEED-VIG.  $ch_n$  fueron organizados como se presenta en la Ecuación 33

$$ch_n = [ FT7, FT8, T7, T8, TP7, TP8, CP1, CP2, P1, PZ, P2, PO3, POZ, PO4, O1, OZ, O2 ]$$

Ecuación 33

En total 85 características son analizadas con una dimensión de 17\*889\*5 (canal\*número\_muestra\*bandas\_frecuencia) implementando la información de los sujetos S1-S10. En la Tabla 15 se presenta la estructura del conjunto de datos para cada sujeto de SEED-VIG.

Tabla 15 Estructura de datos SEEG-VIG construida para el análisis de GALoRSI-SVMRBF

Características	Descripción	Tipo de Datos
Sujetos	10	Numérico. s1-s10
Videos	3	Numérico. (1 a 40)
Etiqueta	Positivas/Negativas	Binaria. Etiqueta.
Número de Muestras Canales	889	Normalizadas
	delta_FT7, delta_FT8, delta_T7, delta_T8, delta_TP7, delta_TP8, delta_CP1, delta_CP2, delta_P1, delta_PZ, delta_P2, delta_PO3, delta_POZ, delta_PO4, delta_O1, delta_OZ, delta_O2, tetha_FT7, tetha_FT8, tetha_T7, tetha_T8, tetha_TP7, tetha_TP8, tetha_CP1, tetha_CP2, tetha_P1, tetha_PZ, tetha_P2, tetha_PO3, tetha_POZ, tetha_PO4, tetha_O1, tetha_OZ, tetha_O2, alpha_FT7, alpha_FT8, alpha_T7, alpha_T8, alpha_TP7, alpha_TP8, alpha_CP1, alpha_CP2, alpha_P1, alpha_PZ, alpha_P2, alpha_PO3, alpha_POZ, alpha_PO4, alpha_O1, alpha_OZ, alpha_O2, beta_FT7, beta_FT8, beta_T7, beta_T8, beta_TP7, beta_TP8, beta_CP1, beta_CP2, beta_P1, beta_PZ, beta_P2, beta_PO3, beta_POZ, beta_PO4, beta_O1, beta_OZ, beta_O2, gamma_FT7, gamma_FT8, gamma_T7, gamma_T8, gamma_TP7, gamma_TP8, gamma_CP1, gamma_CP2, gamma_P1, gamma_PZ, gamma_P2, gamma_PO3, gamma_POZ, gamma_PO4, gamma_O1, gamma_OZ, gamma_O2	85. Características Normalizadas

### 3.2. Parámetros del Modelo

En la Tabla 16 se presentan los parámetros de configuración basados en las investigaciones relacionadas con este trabajo [148][149][122][150] y en las pruebas realizadas durante el desarrollo del modelo. Para las configuraciones de GALoRSI, se encontró que al generar 100 cromosomas en cada generación en un máximo de 30 iteraciones definidas como generaciones utilizando un proceso de selección de cinco comparaciones por generación y con una configuración de cruce y mutación de 0.66 y 0.8 se obtuvieron mejores resultados en la selección de las características. En la Figura 25 se presenta el análisis del desempeño del modelo.

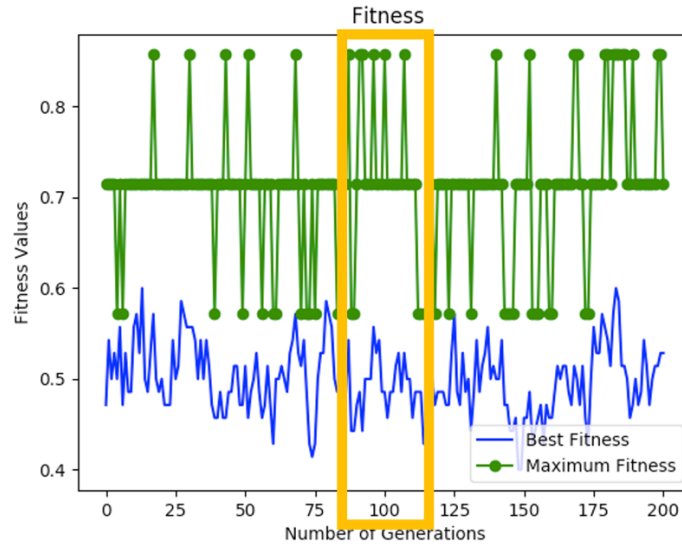


Figura 25 Análisis del desempeño del modelo.

Los parámetros de SVMRBF fueron de  $C = [0.0001, 1000]$  y  $\gamma = [0.00001, 10]$ . Los parámetros para k-NN fueron  $k = [1, 30]$ .

Tabla 16 Tabla de parámetros implementados en el modelo

Parámetros	Valores
Número de generaciones	30
Tamaño de la población	100
Probabilidad de Cruzamiento	0.66
Tipo de Cruzamiento	Dos Puntos
Tipo de Mutación	Mutación Simple
Probabilidad de Mutación	0.8
Técnica de selección	Tournament size:5
$C$	[0.0001, 1000]
$\gamma$	[0.00001, 10]
$k$	[1-30]

#### 4. RESULTADOS

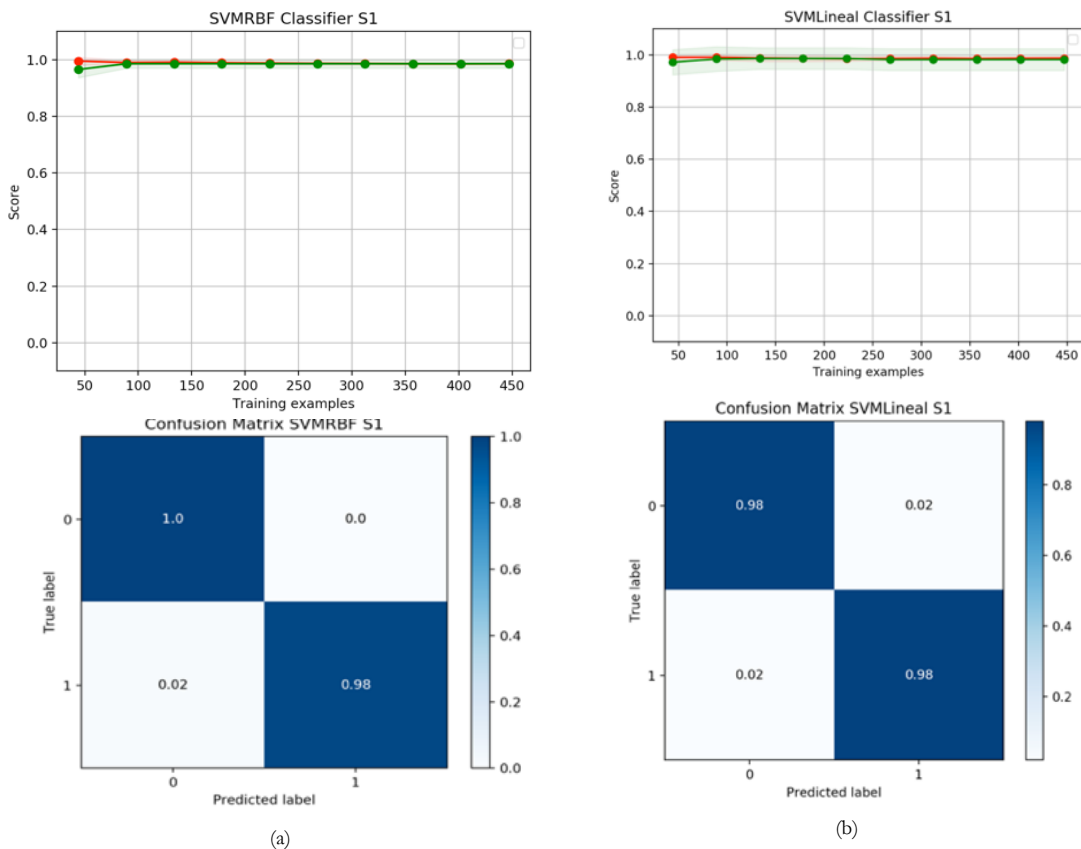
En la Tabla 17 se presentan los resultados obtenidos de GALoRSI-SVMRBF al analizar la información de 10 sujetos. El S1 logró una tasa de exactitud del 98% con una tasa de sensibilidad en la clasificación de los datos del 99% y una tasa de precisión del 97%. S2 obtuvo un 100%, 100% y 100% de exactitud, sensibilidad y precisión. S3 logró un 98%, 98% y 98%. S4 obtuvo un 98%, 94% y 99%. S5 logró un 98%, 98% y 98%. S6 obtuvo un 99%, 99% y 99%. S7 logró un 98%, 96% y 97%. S8 obtuvo un 98%, 96% y 99%. S9 obtuvo un 99%, 98% y 99%. S10 logró un 97%, 96% y 93%. En el Anexo C se presentan a detalle los resultados obtenidos al calcular GALoRSI-SVMRBF por sujeto.

Con el objetivo de evaluar el desempeño de GALoRSI-SVMRBF, los datos de SEED-VIG fueron analizados en dos enfoques. Primero, implementando los algoritmos SVMLINEAL, k-NN y RL en GALoRSI. Segundo, analizando los datos sin implementar el

modelo propuesto utilizando la información directamente en los algoritmos antes mencionados. En la Tabla 17 se presentan los resultados obtenidos de los dos enfoques.

GALoRSI-SVMRBF obtuvo la mejor tasa de exactitud al clasificar los datos con un promedio del 93%, seguido de GALoRSI-RL y GALoRSI-k-NN con un promedio del 84% de exactitud y por último GALoRSI-SVMLINEAL con un promedio de exactitud del 74% al clasificar los datos. En la Figura 26 se observa la curva de aprendizaje obtenida en cada uno de los cuatro modelos al analizar la información de S1. En el gráfico, se describe el proceso de aprendizaje del modelo durante las fases de entrenamiento (rojo) y prueba (verde) donde el eje  $x$  son los datos que el modelo va entrenando y probando. En el eje de las  $y$  se presenta la tasa de precisión que el modelo va obteniendo en cada fase. Por ejemplo, en (a) se observa el desempeño del modelo GALoRSI-SVMRBF, el cual obtuvo un 98% de desempeño durante la fase de entrenamiento. En la fase de prueba, el modelo logró un 99% de desempeño a partir de la muestra 80, concluyendo que el modelo GALoRSI-SVMRBF con la información de S1 necesita aproximadamente 80 muestras para comenzar a obtener una alta tasa de precisión en la clasificación de los datos.

También, en la Figura 26 se observa la matriz de confusión de cada modelo. La matriz contiene la información sobre la clasificación real y pronosticada permitiendo calcular las métricas de desempeño para evaluar cada modelo.



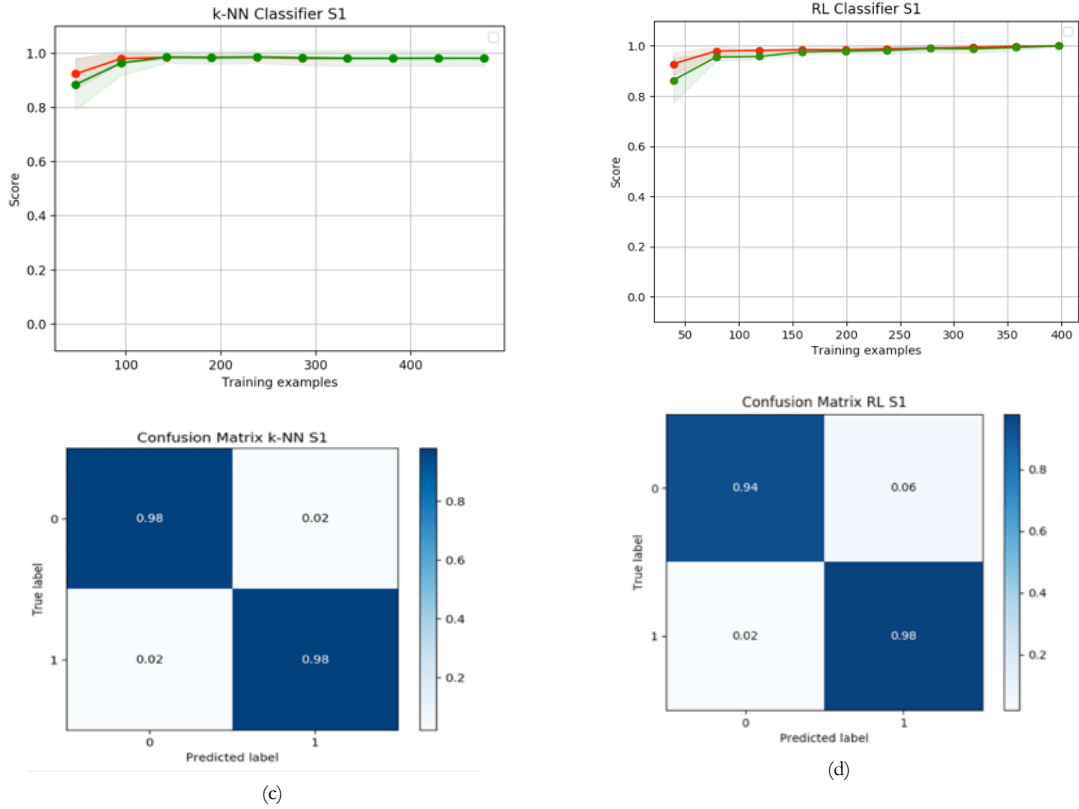


Figura 26 Resultados obtenidos del S1 con SEED-VIG donde en (a)SVMRBF (b)SVML (c)k-NN y (d) RL

Tabla 17 Resultados de SEED-VIG

Resultados del clasificador con la base de datos SEED-VIG									
Sujeto	#	Con GALoRSI				Sin GALoRSI			
		SVMRBF	SVML	k-NN	RL	SVMRBF	SVM Lineal	k-NN	RL
S1	39	98.6034	98.2192	98.1759	98.6274	77.1188	92.3209	89.5551	97.2549
		+/- 0.0354	+/- 0.0832	+/- 0.0487	+/- 0.0823	+/-0.0105	+/- 0.2775	+/- 0.1343	+/- 0.1098
		Sensibilidad	Sensibilidad	Sensibilidad	Sensibilidad	Sensibilidad	Sensibilidad	Sensibilidad	Sensibilidad
		99.0885	d	d	d	50.0	d	d	d
		Precisión	98.2113	98.2113	99.0885	Precisión	93.6883	85.5194	98.1770
		97.1074	Precisión	Precisión	Precisión	38.5542	Precisión	Precisión	Precisión
			96.7949	96.7949	97.1074		87.3644	85.0898	94.5312
S2	37	100.0	100.0	96.5378	97.8787	95.3256	95.3256	97.9411	93.8787
		+/- 0.0	+/- 0.0	+/- 0.0565	+/- 0.1272	+/- 0.0268	+/- 0.0268	+/- 0.0823	+/- 0.1871
		Sensibilidad	Sensibilidad	Sensibilidad	Sensibilidad	Sensibilidad	Sensibilidad	Sensibilidad	Sensibilidad
		100.0	d	d	62.5	d	50.0	d	d
		Precisión	100.0	Precisión	98.9197	Precisión	50.0	98.9197	96.7592
		100.0	Precisión	98.2142	Precisión	47.6470	Precisión	Precisión	Precisión
			100.0		84.7826		47.6470	84.7826	71.6216
S3	32	98.8235	92.8482	97.7089	95.9442	89.6904	52.8482	90.6209	95.7894
		+/-0.0705	+/- 0.2916	+/- 0.1070	+/- 0.1746	+/- 0.3207	+/- 0.0028	+/- 0.2088	+/- 0.2526
		Sensibilidad	Sensibilidad	Sensibilidad	Sensibilidad	Sensibilidad	Sensibilidad	Sensibilidad	Sensibilidad
		98.8599	d	d	d	88.5542	d	d	d
		Precisión	92.1686	96.9879	95.8479	Precisión	50.0	91.3330	95.1807
		98.8599	Precisión	Precisión	Precisión	91.5178	Precisión	Precisión	Precisión
			93.8679	97.4489	96.297		26.4204	91.6351	96.0396
S4	38	98.7593	95.5701	96.6069	95.3759	89.5044	89.5044	93.0418	92.7117
		+/- 0.0276	+/- 0.1031	+/- 0.0540	+/- 0.1138	+/- 0.0095	+/- 0.0095	+/- 0.1265	+/- 0.1160

		Sensibilidad	Sensibilida	Sensibilida	Sensibilida	Sensibilidad	Sensibilida	Sensibilida	Sensibilida		
		94.0677	d	d	d	50.0	d	d	d		
		Precisión	84.0499	85.8442	88.4388	Precisión	50.0	87.8946	90.6880		
		99.3137	Precisión	Precisión	Precisión	44.7508	Precisión	Precisión	Precisión		
			90.9573	92.3180	87.3269		44.7508	80.4472	79.4972		
		98.7670	95.6887	97.1125	95.4462	92.9494	53.3083	85.5532	93.2167		
		+/- 0.0201	+/- 0.1287	+/- 0.0559	+/- 0.1593	+/- 0.1460	+/- 0.0086	+/- 0.1106	+/- 0.0916		
<b>S5</b>	3 2	Sensibilidad	Sensibilida	Sensibilida	Sensibilida	Sensibilidad	Sensibilida	Sensibilida	Sensibilida		
		98.7274	d	d	d	92.5601	d	d	d		
		Precisión	95.4637	97.2062	95.6541	Precisión	50.0	85.4188	93.1381		
		98.7843	Precisión	Precisión	Precisión	93.8228	Precisión	Precisión	Precisión		
			95.9245	97.4282	95.4545		26.6528	85.5064	93.1625		
		98.8630	97.8873	97.4525	99.8591	85.2300	64.7812	83.6199	95.3169		
		+/- 0.0172	+/- 0.0779	+/- 0.0375	+/- 0.0084	+/- 0.2715	+/- 0.0041	+/- 0.1243	+/- 0.0636		
		Sensibilidad	Sensibilida	Sensibilida	Sensibilida	Sensibilidad	Sensibilida	Sensibilida	Sensibilida		
		98.4852	d	d	d	79.1164	d	d	d		
	<b>S6</b>	3 2		Precisión	97.7210	96.6779	99.8908	Precisión	50.0	80.8303	94.7479
			99.0399	Precisión	Precisión	Precisión	90.7473	Precisión	Precisión	Precisión	
			97.6341	98.0949	99.8		32.3903	82.5756	94.9989		
		98.2816	91.9014	95.8736	90.8136	72.6343	72.6343	74.4652	85.6799		
		+/- 0.0265	+/- 0.2305	+/- 0.0559	+/- 0.2617	+/- 0.0079	+/- 0.0079	+/- 0.2591	+/- 0.1625		
		Sensibilidad	Sensibilida	Sensibilida	Sensibilida	Sensibilidad	Sensibilida	Sensibilida	Sensibilida		
		96.8143	d	d	d	50.0	d	d	d		
<b>S7</b>		3 3		Precisión	86.5919	94.0251	89.4087	Precisión	50.0	73.8412	83.6984
				97.9682	Precisión	Precisión	Precisión	36.3166	Precisión	Precisión	Precisión
				92.8266	97.8458	88.1103		36.3166	70.1783	81.7213	
		98.7999	97.1999	98.7833	97.1999	86.3435	83.5435	88.3327	90.2285		
		+/- 0.0720	+/- 0.168	+/- 0.0371	+/- 0.168	+/- 0.1193	+/- 0.0192	+/- 0.1232	+/- 0.2152		
		Sensibilidad	Sensibilida	Sensibilida	Sensibilida	Sensibilidad	Sensibilida	Sensibilida	Sensibilida		
		96.3414	d	d	d	58.5365	d	d	d		
	<b>S8</b>	3 4		Precisión	98.3173	96.3414	98.3173	Precisión	50.0	83.2375	84.4394
				99.2890	Precisión	Precisión	Precisión	92.9752	Precisión	Precisión	Precisión
				92.7083	99.2890	92.7083		41.7670	78.4874	81.9934	
		99.1666	99.1666	99.2307	100.0 +/-	74.3406	74.3406	96.2962	95.4962		
		+/- 0.0500	+/- 0.0500	+/- 0.0461	0.0	+/- 0.0495	+/- 0.0495	+/- 0.1481	+/- 0.1435		
		Sensibilidad	Sensibilida	Sensibilida	Sensibilida	Sensibilidad	Sensibilida	Sensibilida	Sensibilida		
		98.5294	d	d	d	50.0	d	d	d		
<b>S9</b>		3 5		Precisión	98.5294	98.52948	100.0	Precisión	50.0	92.6470	91.1764
				99.4949	Precisión	Precisión	Precisión	37.1212	Precisión	Precisión	Precisión
				99.4949	99.4949	100.0		37.1212	97.5728	97.1153	
		93.4656	91.3499	97.8560	92.9391	90.3970	53.4456	77.9579	86.4901		
		+/- 0.2013	+/- 0.2497	+/- 0.0404	+/- 0.2026	+/- 0.3114	+/- 0.0072	+/- 0.2348	+/- 0.2036		
		Sensibilidad	Sensibilida	Sensibilida	Sensibilida	Sensibilidad	Sensibilida	Sensibilida	Sensibilida		
		92.9886	d	d	d	89.5408	d	d	d		
	<b>S10</b>	3 3		Precisión	90.6927	96.3049	92.47845	Precisión	50.0	77.3276	88.2641
				93.9656	Precisión	Precisión	Precisión	92.2932	Precisión	Precisión	Precisión
				92.3063	96.5711	93.5874		26.7220	78.4112	88.0879	
		98.35299	95.98313	97.53381	96.009344	85.3534	73.20526	87.7384	92.6063		
		Sensibilidad	Sensibilida	Sensibilida	4	Sensibilidad	Sensibilida	Sensibilida	Sensibilida		
		97.39024	d	d	Sensibilida	67.5897	d	d	d		
<b>Total</b>		3 4		Precisión	94.17458	95.56982	d	Precisión	54.8542	84.2277	91.0566
				98.3822	Precisión	Precisión	95.45828	70.1980	Precisión	Precisión	Precisión
			95.2514	93.7785	Precisión		70.1980	84.8823	90.3906		
					94.3679						




Figura 27 Tasa de selección de la información basado en GALoRSI-SVMRBF para identificar las características relevantes de SEED-VIG



Por otro lado, al analizar los datos de SEED-VIG sin la implementación del modelo propuesto, se obtuvo una tasa de predicción al clasificar los datos del 62% con SVMRBF, 61% con k-NN y 57% con SVMLINEAL y RL. Se observó que sin la implementación de GALoRSI la tasa de exactitud decreció en un 36.74%.

En la Figura 27 se presenta la tasa de frecuencia de selección de las características obtenidas de GALoRSI-SVMRBF donde  $\beta_{OZ}$ ,  $\gamma_{O2}$ ,  $\gamma_{OZ}$ ,  $\theta_{PO4}$  y  $\theta_{T8}$  fueron las características con mayor tasa de selección, es decir, el algoritmo identificó que estas características contienen información capaz de describir comportamientos de emociones positivas/negativas. Estos resultados se aproximan a las características seleccionadas en las investigaciones relacionadas a este trabajo utilizando la misma base de datos [157][169][170].

En la Figura 28 se presenta un ejemplo del modelo GALoRSI-SVMRBF entrenado y realizando predicciones de nuevos conjuntos de datos utilizando la información de S1. La información de entrada fue normalizada.

```
X1=[ 1.00924697 0.75196013 -0.0515975 1.04703951 0.4684822 0.46255844
1.23246709 -0.06369549 1.14458694 0.96213151 1.14904211 1.0196929
0.8857459 -0.11911769 1.15394002 0.85257118 1.15967412 0.86624215
0.34687062 1.07139051 1.18592841 1.00815531 0.79857974 1.06850609
0.88661319 1.07177364 0.90011602 -0.39538478 -0.42362793 -0.45946996
-0.84372898 -0.59731168 -0.5908006 -0.38544893 -0.63274791 -0.66010498
-0.67868874 -0.68086895 -0.54296961], Predicted=1
X2=[-0.51203335 -0.05094105 -0.17757434 -0.0910397 0.70957493 0.67964293
-0.23686724 -0.15897235 -0.44729253 0.1718742 0.24681012 0.31210849
0.71345606 -0.12740322 0.35646238 0.61110263 0.33497775 0.58256689
0.13131612 1.75618348 1.81457121 1.21520878 1.08101151 1.25807076
0.9125584 1.24205825 1.64091217 0.65863486 3.70516502 2.62120164
2.41572303 1.64807307 1.67179905 -0.28571718 -0.32251342 -0.11978457
-0.09033345 -0.03446982 -0.41426701], Predicted=1
X3=[-0.74101682 -0.87059736 -0.23738087 -0.94827033 -0.95722294 -0.95338581
-0.87173474 -0.18015091 -0.88702 -1.31488109 -1.24974931 -1.03337398
-1.3582431 -0.22139498 -1.4821223 -1.39223734 -1.48306323 -1.39165191
-0.74231356 -1.19677221 -1.24353427 -1.1722298 -1.5888725 -1.54908419
-1.5884305 -1.53050259 -1.29837576 1.17267873 -0.5366038 -0.75801899
-0.68126115 -0.94656303 -0.97446895 2.0525248 0.78799642 0.93276145
0.83328997 0.66804703 1.14922375], Predicted=0
X4=[-0.51730947 -0.37587988 -0.19597302 -0.32966921 0.15788525 0.13905998
-0.42717259 -0.16194024 -0.41289583 -0.16744533 0.08211697 0.27190483
0.29996045 -0.13493551 0.68071153 0.45142181 0.67176475 0.43306236
0.18964263 -0.31959521 -0.14872863 -0.07024814 0.03403694 -0.2449063
-0.09447913 -0.27740438 -0.33454422 -0.17699942 0.43231388 0.84455621
0.10926746 0.49952559 0.48220745 -0.31932463 -0.34862065 -0.14714673
-0.25592484 -0.06792039 -0.46705018], Predicted=1
X5=[ 0.83689382 0.95976985 -0.11263782 0.56978048 0.11010111 0.10500751
0.50222563 -0.1164326 0.2860452 0.59155887 0.70508669 0.71682533
0.66176911 -0.1396432 0.483533 0.41247527 0.48610012 0.40622821
0.0539701 0.18329963 0.21878562 0.51640334 0.22281434 0.25608605
0.28491773 0.25964707 0.20711318 -0.49669556 -0.88982057 -1.02398345
-0.97828384 -0.90121289 -0.90443643 -0.38774554 -0.63214014 -0.66394764
-0.63512015 -0.74760503 -0.53793887], Predicted=1
```

Figura 28 Predicción de nuevos conjuntos de datos de entrada del modelo GALoRSI-SVMRBF entrenado

En la figura se observan 5 nuevos conjuntos de datos de entrada, los cuales fueron analizados en el modelo entrenado utilizando la información de S1. El modelo predijo que el comportamiento de la información del conjunto X1 está relacionada con estados de



emociones negativas el cual fue etiquetado como 1. El comportamiento de la información de X2 está relacionada con emociones negativas etiquetado como 1. X3 está relacionada con emociones positivas etiquetado como 0. X4 está relacionada con emociones negativas etiquetado como 1. Por último, la información de X5 está relacionada con emociones negativas etiquetado como 1. Los resultados fueron comparados con el valor real de la etiqueta confirmando que el modelo entrenado con la información S1 tiene una tasa de predicción del 98% como se observa en la Tabla 17

## 5. DISCUSIONES Y CONCLUSIONES

En la literatura, se han propuesto diversas investigaciones relacionadas a este trabajo enfocadas en el desarrollo de modelos capaces de identificar y predecir el comportamiento interno del sujeto implementando SEED-VIG como se muestra en la Figura 29. A continuación, se presentan los trabajos más destacados en los recientes años.




Figura 29 Modelos relacionados a este trabajo implementando SEED-VIG

En [157] proponen seis combinaciones de electrodos de 310, 135, 270 y 115 características implementando MRMR (minimal redundancy maximal relevance algorithm), PCA y diversos algoritmos de aprendizaje automático para reducir y clasificar los datos obteniendo un 91.07% de precisión. Ellos encontraron 20 características relevantes de los canales de alfa (FT8), beta (AF4, F6, F8, FT7, FC5, FC6, FT8, T7, TP7) y gamma (FP2, AF4, F4, F6, F8, FT7, FC5, FC6, T7, C5). En [169] utilizan 62 canales de las bandas theta, alfa, beta y gamma e implementan los algoritmos de Chi-cuadrada, información mutua, análisis de la varianza, eliminación de las características recursivas (RFE - Recursive Feature Elimination) y L1-norm para seleccionar y clasificar las características logrando un 83.33% de precisión. En [169] proponen analizar 10 conjuntos de datos de 620 características cada uno utilizando el algoritmo ST-SBSSVM (significance test, sequential backward selection, and support vector machine) para seleccionar y clasificar los datos, obteniendo un 89% de precisión. En [170] definieron los canales C5, C6, CP5, CP6, FT7, FT8, P7, P8, T7, T8, TP7, y TP8 como los

más relevantes e implementaron IP (Information Potential), bosque aleatorio y SVM para seleccionar y clasificar los datos obteniendo 90.48% de precisión. En [73] analizan 6 conjuntos de datos de  $62 \times 5$  (canales\*bandas) dimensiones cada uno utilizando CDCN (Channel fused Dense Convolutional Network ) logrando un 90% de precisión. Ellos sugieren que la banda beta y gamma son capaces de identificar mejor los estados emocionales que el resto de las bandas de frecuencia. En [73] analizaron dos conjuntos de datos de  $18 \times 5$  y  $62 \times 5$  (canales\*bandas) dimensiones utilizando CNF (Connectivity Network Features) y DCCAM (Deep Canonical Correlation Analysis Model) para seleccionar y clasificar los datos logrando un 84.51% de precisión. Ellos sugieren que reducir el conjunto de canales a FP1, FP2, F7, F3, FZ, F4, F8, T7, C3, CZ, C4, T8, P7, P3, P4, P8, O1 y O2 se obtienen mejores resultados. En [171] analizaron un conjuntos de datos de  $62 \times 5$  (canales\*bandas) dimensiones utilizando el algoritmo CNN (Convolutional Neural Network) y SVMRBF logrando un 91% y 81% de precisión. En [172] analizaron 14 (Fp1-Fp2, AF3-AF4, F7-F8, F3-F4, FC5- FC6, FC1-FC2, T7-T8, CP1-CP2, P7-P8, P3-P4, Po3-PO4, O1-O2) y 13 (Fp1-O1, Fp2-O2, AF3-Po3, AF4-Po4, F7-P7, F8- P8, F3-P3, F4-P4, Fz-Pz, FC5-CP5, FC6-CP6, FC1-CP1, FC2-CP2) pares de canales utilizando CCA (Canonical Correlation Analysis), SVM y GELM (Graph regularized Extreme Learning Machine) para seleccionar y clasificar la información logrando un 88% de precisión con la banda gamma en GELM. En [173] analizaron un conjunto de datos de  $62 \times 5$  (canales\*bandas) dimensiones utilizando LSTM (Long Short Term Memory) logrando un 93.97% de precisión. En [113] analizaron 35 canales utilizando PCA, t-statistic, SVM, ANN, LDA y kNN para extraer y clasificar las características obteniendo un 86% de precisión con ANN. En [174] propone una estructura de red jerárquica con nodos de subred para discriminar tres emociones utilizando 62 y 12 canales (FT7, FT8, T7, T8, C5, C6, TP7, TP8, CP5, CP6, P7, y P8) logrando un 91% y 93% de precisión. En [175] analizaron cuatro conjuntos de  $4 \times 5$ ,  $12 \times 5$ ,  $20 \times 5$  y  $62 \times 5$  (canales\*bandas) dimensiones utilizando el algoritmo GSCCA (Group Sparse Canonical Correlation Analysis) obteniendo un 82% de precisión seleccionando 20 canales relevantes. En [176] analizaron 291 canales utilizando DASM (Differential Asymmetry), RASM (Rational Asymmetry), SVM y ANN para seleccionar y clasificar características obteniendo un 91% de precisión. En esta investigación, los resultados obtenidos con GALoRSI-SVMRBF al implementar SEED-VIG fueron en promedio del 98.35% de precisión, reduciendo un 60% el conjunto de datos original y logrando un tiempo de procesamiento de 73.03 segundos.

En este capítulo, se presenta la fase de validación del modelo de predicciones denominado GALoRSI-SVMRBF utilizando la base de datos internacional SEED-VIG. GALoRSI-SVMRBF fue construido, centrándose en la selección de las características, estructuración de la información y construcción de un clasificador con el objetivo de crear un sistema capaz de modelar datos multidimensionales y obtener predicciones más exactas.

En esta investigación, se implementó una base de datos internacional con el objetivo de analizar el desempeño del modelo. Además, fueron utilizados diversos algoritmos supervisados para comparar los resultados demostrando que GALoRSI-SVMRBF obtuvo el mejor rendimiento y porcentaje de predicción. También, como se observa en la Figura 29

los resultados de esta investigación fueron comparados con otros modelos de la literatura que implementaron SEED-VIG logrando en promedio un 88.66% de precisión. GALoRSI-SVMRBF obtuvo en promedio un 98% mejorando un 9.34% la tasa de predicción.

Con la implementación de una base de datos internacional en GALoRSI-SVMRBF se descubrió que el modelo es capaz de identificar información EEG relevante, al comparar las características seleccionadas por el modelo con la información utilizada en otras investigaciones. Además, se demostró que el módulo es capaz de soportar y adaptarse a nuevos conjuntos de datos multidimensionales. Por otro lado, se observó que el tiempo computacional que requiere nuestro modelo se mantiene en un rango medio aceptable al compararlo con los modelos propuestos en [97] y [161] utilizando los algoritmos ReliefF, PCA, GA, RNCA y diversos algoritmos evolutivos.



## CAPÍTULO VI

### ANÁLISIS DEL DESEMPEÑO DEL MODELO DE PREDICCIONES DE ESTADOS COGNITIVOS

En este capítulo, se presenta el análisis de desempeño de GALoRSI-SVMRBF con el objetivo de conocer los alcances y limitaciones del modelo encontrando la mejor configuración para obtener una alta tasa de predicción con el mejor rendimiento.

Para llevar a cabo el análisis de desempeño del modelo, fue utilizada la base de datos internacionales de señales EEG DEAP (Emotion Analysis using Physiological Signals) [116].

Parte de la información de este capítulo fue utilizada como soporte para preparar el artículo titulado “Emotion Recognition Model based on Genetic Algorithms, Logistic Regression and Vector Support Machines using EEG Signals”.

#### 1. INTRODUCCIÓN

Los algoritmos genéticos (AGs) computacionales propuestos por primera vez en [177] son utilizados principalmente para la selección de características preservando la información identificada como relevante. Los AGs tradicionales consisten en estructurar los datos en forma de un cromosoma donde cada elemento del cromosoma se codifica en una cadena binaria donde si el elemento tiene el valor de "1" es seleccionado para continuar el proceso evolutivo y encontrar la solución del problema a resolver, mientras que aquellas que tienen el valor "0" son rechazados [53].

En general, los AGs se enfrentan a dos principales problemas: convergencia prematura y complejidad computacional. La convergencia prematura surge cuando los primeros cromosomas son rápidamente clasificados como relevantes sin la posibilidad de explorar otros elementos prometedores [178]. Existen muchas causas de la convergencia prematura (mal diseño de la función de ajuste, relación desproporcionada entre la exploración y extracción de los datos, entre otros), sin embargo, la principal causa se debe al crear la población y su diversidad [179].

Por otro lado, la complejidad computacional en los AGs es causada principalmente por el extenso volumen de datos que pasa por un proceso de análisis evolutivo. Al incrementar la cantidad de datos, incrementa el proceso de búsqueda multidireccional seleccionando y juzgando cada elemento en paralelo incrementando el tiempo de análisis y procesamiento de los datos [111][164].

Aunque es sabido que los grandes volúmenes de datos son la clave para encontrar la solución en los problemas de aprendizaje automático [180], también, representa la parte más costosa y compleja desde el punto de vista computacional y algorítmico. Por ello, es

importante analizar el desempeño de los modelos encontrando el balance entre datos, procesos y resultados.

En este capítulo, se presenta el análisis del desempeño del modelo GALoRSI-SVMRBF evaluando diferentes escenarios de datos para estudiar sus alcances y limitaciones con el objetivo de encontrar la mejor configuración para enfrentar los principales problemas de AG y obtener una alta tasa de predicción con el mejor rendimiento del modelo.

GALoRSI-SVMRBF fue examinado utilizando las métricas de exactitud en la clasificación de los datos, tiempo de procesamiento y escalabilidad de datos para analizar su desempeño. Además, fueron utilizados los algoritmos SVMLineal, k-NN y RL para evaluar y comparar los resultados del análisis del modelo propuesto.

Para llevar a cabo el análisis de desempeño del modelo, fue utilizada la base de datos internacionales DEAP (Dataset Emotion Analysis using Physiological Signals) [116]. DEAP fue creada con el objetivo de desarrollar un sistema de reconocimiento de emociones basado en la identificación de videos musicales. DEAP se ha utilizado en una serie de estudios con el propósito de evaluar nuevos algoritmos [116][181].

Este capítulo está organizado de la siguiente manera. En la sección 2 se describen las métricas utilizadas para evaluar al modelo propuesto. La sección 3 presenta las herramientas y parámetros utilizados. Los resultados y discusiones son presentados en la sección 4. Finalmente, las conclusiones son presentadas en la sección 5.

## 2. MÉTRICAS

El desempeño de GALoRSI-SVMRBF fue evaluado utilizando las métricas de exactitud, tiempo computacional y escalabilidad en la información implementando diferentes conjuntos de datos para examinar su desempeño. A continuación, se presentan cada una de las métricas utilizadas.

### 2.1. Exactitud

La exactitud es una métrica que determina la calidad del modelo o su grado de veracidad, evaluando el porcentaje de casos que ha acertado el modelo al realizar la predicción con respecto al valor real [182]. Esta métrica es calculada como se presenta en la Ecuación 34

$$\frac{\text{Número de casos de correctas predicciones}}{\text{Número total de predicciones realizadas}} * 100$$

Ecuación 34

donde es calculado el número de predicciones correctas realizadas por el modelo entre el número total de predicciones realizadas. Si un modelo logra obtener una tasa de exactitud del 100% indicará que todas las predicciones realizadas son correctas.

## 2.2. Tiempo de procesamiento

El tiempo de procesamiento es el tiempo que utiliza la unidad central de procesamiento (CPU-Central Processing Unit) para procesar una secuencia de instrucciones provenientes de un programa, algoritmo o modelo.

Esta métrica es utilizada como una medida para cuantificar el coste computacional de un algoritmo. Cuando el tiempo de procesamiento de un algoritmo es alto, indica que la cantidad de cálculos necesarios para resolver el problema ha incrementado considerablemente, sobrepasando los recursos computacionales disponibles [183].

En [184] presentan diferentes técnicas para medir el tiempo de procesamiento de un algoritmo. En este estudio, es calculado como un intervalo de tiempo analizando el tiempo real que ha transcurrido desde que inicia la ejecución de instrucciones del algoritmo hasta que finaliza [4]. Esta métrica es calculada como se presenta en la Ecuación 35

$$Tiempo_{total} = Tiempo_{final} - Tiempo_{inicial}$$

Ecuación 35

*Tiempo<sub>inicial</sub>* tiempo donde se inicia la ejecución del programa. *Tiempo<sub>final</sub>* tiempo donde se realiza la última instrucción del programa. *Tiempo<sub>total</sub>* es el tiempo transcurrido y es medido en segundos (s) donde evalúa los tiempos de entradas y salidas de datos, los retrasos multitarea y todos los demás tipos de espera en los que incurre el programa. Con GALoRSI-SVMRBF son considerados diversos aspectos para calcular el tiempo total. Estos aspectos son: el proceso evolutivo, búsquedas, análisis y estructuración de la población, complejidad de la función de ajuste, configuración de parámetros, fase de entrenamiento y fase de prueba.

## 2.3. Escalabilidad

La escalabilidad analiza la habilidad de un modelo o sistema para reaccionar y adaptarse a un nuevo entorno a medida que este aumenta o disminuye de forma significativa el volumen de datos. En otras palabras, evalúa el manejo del crecimiento continuo de datos en el modelo de manera fluida. Cuando un modelo tiene la capacidad para procesar conjuntos de datos de diversos tamaños sin afectar su velocidad y calidad de respuesta, se define comúnmente como “modelo escalable” [185].

En este estudio, fue calculada la métrica de escalabilidad evaluando diferentes tamaños de datos para analizar el porcentaje de exactitud y el tiempo de procesamiento como se presenta en Ecuación 36

$$TamañoDatos_x = [MayorExactitud, MenorTiempo procesamiento]$$

Ecuación 36

donde  $x$  son las características que conforman el conjunto de datos. Para este análisis  $x$  incrementará en un  $[x + 20]$  obteniendo un total de 6 conjuntos de datos de  $[20,40,60,80,100,120]$  características. *Exactitud* analiza el porcentaje de exactitud en la predicción realizada por el modelo en cada conjunto de datos. *Tiempo procesamiento* analiza

el tiempo total transcurrido para ejecutar el programa en cada conjunto de datos. El conjunto de datos que tenga una mayor tasa de exactitud en un menor tiempo de procesamiento será considerado como el tamaño óptimo de datos que el modelo es capaz de soportar.

### 3. HERRAMIENTAS Y PARÁMETROS

#### 3.1. Parámetros del Modelo

Los parámetros establecidos para el modelo utilizando DEAP fueron basados en las investigaciones relacionadas con este trabajo [122][148][149][150] y al evaluar el modelo durante la fase de construcción. En la Figura 30, se observa que el modelo obtuvo el mejor desempeño en la generación 50, por lo cual, las configuraciones establecidas fueron: 100 cromosomas en cada generación en un máximo de 50 iteraciones utilizando una tasa de selección de cinco comparaciones por generación y con una configuración de cruce y mutación de 0.66 y 0.8.

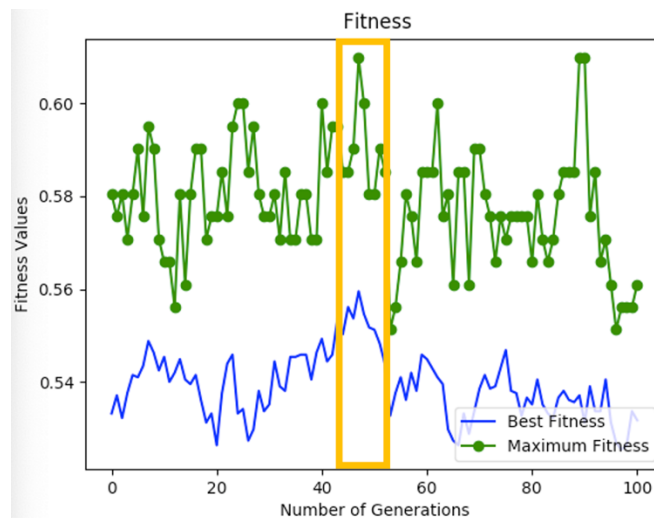


Figura 30 Evaluación del desempeño del modelo analizando diferentes configuraciones

#### 3.2. Hardware

Los experimentos se llevan a cabo utilizando un ordenador portátil con un procesador Intel Core i7 (2.8GHZ) y una memoria RAM de 16 GB. El modelo propuesto fue desarrollado utilizando el software Visual Studio Code V.1.31. y la versión de controles de cambios GitLab y GitHub.

#### 3.3. Bases de Datos DEAP

DEAP es una base de datos de señales EEG que analiza los estados afectivos humanos propuesta por la Universidad Queen Mary de Londres [116]. El conjunto de datos contiene la información de 32 participantes donde cada participante observó 40 extractos de videos musicales de un minuto de duración cada video.



En el experimento, utilizaron un sensor de 32 electrodos con una frecuencia de muestreo de 512Hz para grabar las señales EEG. También, utilizaron la autoevaluación SAM (Self-Assessment Manikins) como referencia para identificar el estado emocional del sujeto en cada video [186]. SAM evalúa las categorías de excitación, valencia, gusto y dominación donde el participante selecciona un valor en la escala de 1-9 para indicar su estado emocional en el cual 1 es una emoción negativa y 9 es una emoción positiva como se muestra en la Figura 31. En general, la categoría de excitación evalúa las emociones pasivas-activas, por ejemplo, de calmada a excitación. La categoría de valencia evalúa las emociones negativas-positivas, por ejemplo, de tristeza a felicidad. La categoría de gusto está relacionada con el sabor y la categoría de dominación está relacionada con la emoción del control de una situación que puede ir desde el control absoluto hasta el control total [187].

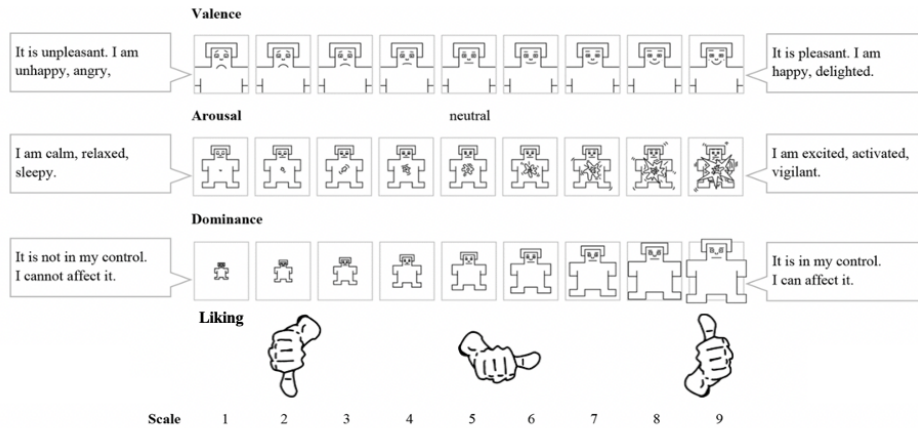


Figura 31 Sistema de autoevaluación SAM [188]

Las señales EEG recolectadas durante los experimentos de DEAP, fueron categorizadas utilizando el sistema de excitación (baja/alta) y valencia (baja/alta) de SAM. Este sistema fue propuesto por primera vez en [116] y consiste en que los datos (EEG) son mapeados en un esquema de clasificación binaria definido como cuadrante cognitivo bidimensional para etiquetar los datos como se muestra en la Figura 32. Los datos de las señales EEG localizados en el cuadrante [1-5] son categorizados como baja valencia/excitación y los datos localizados en el cuadrante [5-9] son categorizados como alta valencia/excitación.




Figura 32 Cuadrante cognitivo bidimensional (a) Alta/Baja Valencia y (b) Alta/Baja Excitación [189]

### 3.4. Procesamiento y Estructuración de DEAP

DEAP tiene una versión pre-procesada de las señales EEG que es ampliamente utilizada para probar algoritmos en la literatura [190]. El preprocesamiento de los datos consistió en disminuir la frecuencia de muestreo de 512Hz a 128Hz para eliminar valores atípicos e implementan el enfoque de densidad de espectro de potencia (PSD- Power Spectrum Density) basado en la Transformada Rápida de Fourier (FFT- Fast Fourier Transform) para extraer cuatro rangos de frecuencia como proponen en [35][191][192]. Estos rangos de frecuencia son definidos bandas de frecuencia los cuales son: delta (1-4), theta (4–8 Hz), alfa (8–13 Hz) y beta (13–30 Hz). Los datos extraídos fueron organizados en una matriz de 40\*40\*8064 (prueba\*canal\*muestras) dimensiones para cada sujeto.

En [193][194][195] proponen diversas técnicas para organizar la información de DEAP. En esta investigación, los datos extraídos son normalizados y organizados en una matriz compuesta por canales\* muestras \*bandas\_frecuencia como se presenta en la Ecuación 37.

$$\text{ConjuntoDatos} = [\text{Delta}_{ch_1, \dots, ch_n}, \text{Theta}_{ch_1, \dots, ch_n}, \text{Alfa}_{ch_1, \dots, ch_n}, \text{Beta}_{ch_1, \dots, ch_n}]^M$$

Ecuación 37

donde la información fue organizada siguiendo el orden de las bandas de frecuencia (delta, theta, alfa y beta).  $ch_n$  son los canales utilizados en DEAP organizados como se presenta en la Ecuación 38

$$ch_n = [F3, F7, FC5, FC1, C3, T7, CP5, CP1, P3, P7, PO3, O1, Oz, Pz, Fp2, AF4, Fz, F4, F8, FC6, FC2, Cz, C4, T8, CP6, CP2, P4, P8, PO4, O2]$$

Ecuación 38

En este trabajo, el conjunto de datos de DEAP fue analizado utilizando el enfoque de valencia donde los datos son etiquetados como  $valencia = [baja|alta]$  donde baja=0 y alta=1. Sólo fue implementado un enfoque debido a que el objetivo de este capítulo es analizar el desempeño del modelo y no la tasa de predicción.

En total, 120 características son analizadas con una dimensión de 30\*8064\*4 (canal\*número\_muestra\*bandas\_frecuencia) implementando la información de los sujetos S1-S10 donde los canales Fp1 y AF3 son descartados debido a que presentaron valores atípicos [169]. En la Tabla 18 se presenta la estructura del conjunto de datos construida para cada sujeto.

## 4. RESULTADOS Y DISCUSIONES

En esta sesión son presentados los resultados obtenidos al evaluar el desempeño de GALoRSI-SVMRBF utilizando la base de datos DEAP. El análisis fue llevado a cabo utilizando las métricas de exactitud, tiempo de procesamiento y escalabilidad implementando SVMRBF, SVMLineal, k-NN y RL para examinar el desempeño del modelo.

Tabla 18 Estructura de datos DEAP construida para el análisis de GALoRSI-SVMRBF

Selección de Características	Selección de Características	Selección de Características
Sujetos	10	Numérico
Videos	40	S1-S10
Etiqueta	Valencia=[Baja/Alta] Excitación=[Baja/Alta]	Numérico (1 a 40) Etiqueta Binaria
Número de Muestras	8064	Normalizadas
Canales	delta_F3, delta_F7, delta_FC5, delta_FC1, delta_C3, delta_T7, delta_CP5, delta_CP5, delta_CP1, delta_P3, delta_P7, delta_PO3, delta_PO1, delta_OZ, delta_PZ, delta_FP2, delta_AF4, delta_FZ, delta_F4, delta_F8, delta_FC6, delta_FC2, delta_CZ, delta_C4, delta_T8, delta_CP6, delta_CP2, delta_P4, delta_P8, delta_PO4, delta_O2, theta_F3, thetaF7, thetaFC5, theta_C3, thetaFC1, theta_T7, theta_CP5, theta_CP1, theta_P3, theta_P7, theta_P03, theta_P01, theta_OZ, theta_PZ, theta_FP2, theta_AF4, theta_FZ, theta_F4, theta_F8, theta_FC6, theta_FC2, theta_CZ, theta_C4, theta_T8, theta_CP6, theta_CP2, theta_P4, theta_P8, theta_PO4, theta_O2, alpha_F3, alpha_F7, alpha_FC1, alpha_FC5, alpha_FC3, alpha_T7, alpha_CP5, alpha_CP1, alpha_P3, alpha_P7, alpha_PO3, alpha_PO1, alpha_OZ, alpha_PZ, alpha_FP2, alpha_AF4, alpha_FZ, alpha_F4, alpha_F8, alpha_FC6, alpha_FC2, alpha_CZ, alpha_C4, alpha_T8, alpha_CP6, alpha_CP2, alpha_P4, alpha_P8, alpha_PO4, alpha_O2, beta_F3, beta_F7, beta_FC5, beta_FC1, beta_C3, beta_T7, beta_CP5, beta_CP1, beta_P3, beta_P7, beta_PO3, beta_PO1, beta_OZ, beta_PZ, beta_FP2, beta_AF4, beta_FZ, beta_F4, beta_F8, beta_FC6, beta_FC2, beta_CZ, beta_C4, beta_T8, beta_CP6, beta_CP2, beta_P4, beta_P8, beta_PO4, beta_O2	120 Características Normalizadas

#### 4.1. Resultados de SVMRBF

En la Tabla 19 se muestran los resultados obtenidos al evaluar el desempeño de GALoRSI-SVMRBF. En la tabla, se presentan los elementos seleccionados y los resultados obtenidos durante la fase de entrenamiento y prueba del modelo al evaluar las métricas de exactitud y tiempo de procesamiento analizando diferentes conjuntos de datos.

Como se observa, el conjunto de datos de 80 característica obtuvo el mejor resultado en las fases de entrenamiento y prueba del modelo con una tasa de exactitud al clasificar los datos de 89.45% y 90.21%. Seguido del conjunto de 20 características con una exactitud del 82.87% y 84.92%. El conjunto con 40 características obtuvo un 73.84% y 78.08%. El conjunto con 120 características obtuvo un 71.73% y 79.21%. El conjunto con 60 características obtuvo un 71.77% y 78.59%. Finalmente, el conjunto con 100 características obtuvo 70.54% y 84.02%.

Se observó que, en promedio, el tiempo de procesamiento del modelo es de 116.03s en la fase de entrenamiento y de un 2.27s en la fase de prueba, logrando reducir el tiempo en un 98%.

En la Figura 33 y Figura 34 se presenta el análisis de la tasa de exactitud y el tiempo de procesamiento obtenido en cada conjunto de datos durante las fases de entrenamiento y prueba. Como se observa en la Figura 33, a medida que incrementó el número de características, fue incrementando en promedio 25s el tiempo de procesamiento entre cada conjunto. Por otro lado, la tasa de exactitud no fue incrementando significativamente entre conjuntos.

En la Figura 34 se observa los resultados obtenidos al evaluar el modelo entrenado con el conjunto de datos de prueba. En promedio, el tiempo de procesamiento incrementó un 0.18s entre conjuntos. Se observa, que el modelo entrenado logra obtener una tasa de exactitud del 90.21% en un tiempo de 2.09s.

Tabla 19 Resultados obtenidos de evaluar el modelo GALoRSI utilizando SVMRBF

Conjunto Datos	Características Seleccionadas	# gens	Entrenamiento		Prueba	
			Exac	Tiempo	Exac	Tiempo
20	['beta_P4', 'delta_FZ', 'delta_F8', 'alpha_P3', 'theta_PO1', 'theta_CP6', 'theta_FC6', 'alpha_CP1', 'thetaFC5', 'delta_FC2', 'beta_O2']	11	82.87	63.9103	84.92	1.7179
40	['theta_FP2', 'delta_P7', 'alpha_F7', 'alpha_CP1', 'beta_CP5', 'theta_CP1', 'alpha_PO1', 'alpha_T8', 'alpha_F8', 'theta_CZ', 'alpha_T7', 'theta_CP5', 'beta_T8', 'delta_AF4', 'theta_T8', 'delta_FC6', 'alpha_O2', 'beta_P7', 'theta_PZ', 'beta_F3']	20	73.84	78.3918	78.08	2.2902
60	['delta_P7', 'beta_F8', 'alpha_F3', 'theta_FP2', 'beta_P7', 'delta_FC1', 'theta_P3', 'alpha_C4', 'delta_P8', 'theta_P7', 'delta_P4', 'beta_OZ', 'beta_P3', 'alpha_PO3', 'delta_F8', 'alpha_PO4', 'alpha_P7', 'delta_CP2', 'delta_CP5', 'alpha_CZ', 'thetaFC5', 'alpha_CP1', 'alpha_CP5', 'alpha_F4', 'beta_CP5', 'theta_T7', 'theta_P8', 'theta_P03', 'beta_F3', 'delta_FZ']	30	71.77	93.1739	78.59	1.7423
80	['beta_FC6', 'theta_T8', 'theta_P8', 'beta_CP1', 'alpha_AF4', 'theta_P4', 'theta_FC6', 'delta_P3', 'theta_PZ', 'delta_CP2', 'delta_F7', 'alpha_T8', 'alpha_PO4', 'delta_P7', 'delta_FC1', 'thetaFC5', 'beta_OZ', 'theta_CP2', 'delta_FP2', 'delta_PO4', 'delta_P4', 'alpha_F3', 'alpha_FC6', 'alpha_OZ', 'beta_FZ', 'thetaF7', 'beta_FC5', 'alpha_CP2', 'alpha_FP2', 'thetaFC1', 'delta_T8', 'alpha_PO3', 'delta_PZ', 'theta_CZ', 'beta_C3', 'theta_O2', 'beta_AF4']	37	89.45	118.92	90.21	2.0984
100	['alpha_FC6', 'beta_FP2', 'theta_P3', 'alpha_P4', 'theta_F4', 'beta_F4', 'theta_PO4', 'delta_FC1', 'alpha_C4', 'alpha_FC5', 'delta_FC6', 'theta_F8', 'delta_PZ', 'beta_O2', 'theta_F3', 'delta_P4', 'alpha_F8', 'alpha_FZ', 'beta_T7', 'delta_F4', 'beta_P3', 'theta_T7', 'theta_C4', 'thetaF7', 'beta_FC1', 'theta_AF4', 'delta_OZ', 'theta_FC6', 'delta_CP6', 'theta_PO1', 'alpha_AF4', 'beta_F7', 'theta_OZ', 'beta_AF4', 'alpha_CP6', 'beta_FZ', 'delta_O2', 'delta_C4', 'delta_P3', 'delta_FZ', 'beta_CP5', 'alpha_T8', 'beta_CP6', 'theta_CP6', 'delta_CP5', 'beta_F3', 'alpha_CP5', 'beta_PO4', 'theta_T8', 'alpha_PO1', 'theta_C3', 'beta_C3', 'delta_CZ', 'alpha_CP2']	54	70.54	152.9284	84.02	3.1187
120	['beta_FC2', 'theta_F4', 'delta_F4', 'beta_AF4', 'alpha_C4', 'delta_CP5', 'alpha_CP1', 'alpha_CP5', 'beta_F4', 'alpha_PO1', 'delta_FC1', 'delta_PO3', 'theta_FZ', 'beta_OZ', 'delta_PO4', 'thetaFC1', 'alpha_F3', 'delta_T7', 'beta_P4', 'delta_OZ', 'beta_PZ', 'alpha_PZ', 'theta_FC2', 'beta_P3', 'beta_FP2', 'delta_PO1', 'beta_PO1', 'delta_P8', 'delta_FC6', 'alpha_F8', 'theta_CP6', 'theta_CZ', 'delta_PZ', 'beta_FZ', 'alpha_P7', 'delta_CZ', 'theta_PZ', 'beta_CP5', 'theta_FC6', 'delta_FC5', 'beta_C4', 'delta_P3', 'delta_F3', 'alpha_OZ', 'alpha_FC2', 'delta_AF4', 'beta_T7', 'beta_F7', 'alpha_AF4', 'delta_F8', 'beta_P8', 'theta_O2', 'alpha_O2', 'theta_P03', 'beta_PO4']	55	71.73	188.9210	79.21	2.6626
<b>Total</b>			76.7	116.0383	82.50	2.2716

#### 4.2. Resultados de SVMLineal

En la Tabla 20 se presentan los resultados obtenidos al evaluar el modelo GALoRSI implementando el algoritmo SVMLineal. Como se observa, el conjunto de datos de 100 características obtuvo el mejor resultado en la fase de entrenamiento y prueba del modelo con una tasa de exactitud al clasificar los datos de 55.82% y 71.48%. Seguido del conjunto con 60 características con una exactitud del 55.80% y 69.53%. El conjunto con 120 características obtuvo un 55.78% y 73.14%. El conjunto con 80 características obtuvo un 55.74% y 70.93%. El conjunto con 40 características obtuvo un 55.72% y 71.60%. Finalmente, el conjunto con 20 características obtuvo una tasa de exactitud de 55.64% y 60%.

Durante la fase de entrenamiento, el modelo logró en promedio un tiempo de procesamiento de 195.23s y en la fase de prueba el modelo obtuvo en promedio un tiempo de 2.66s reduciendo el tiempo de procesamiento en un 98%.




Figura 33 Análisis del desempeño del GALoRSI-SVMRBF en la fase de entrenamiento




Figura 34 Análisis del desempeño del GALoRSI-SVMRBF en la fase de prueba

En la Figura 35 y Figura 36 se presenta el análisis de la tasa de exactitud y el tiempo de procesamiento obtenido en cada conjunto de datos durante las fases de entrenamiento y prueba. Como se observa en la Figura 35, a medida que fue incrementando el tamaño de características fue incrementando en promedio 23s el tiempo de procesamiento.

En la Figura 36 se observa que en promedio el tiempo de procesamiento entre cada conjunto incrementó 0.26s durante la fase de prueba, incrementando con ello la tasa de exactitud hasta un 73.14%.

Tabla 20 Resultados obtenidos de evaluar el modelo GALoRSI utilizando SVMLineal

Conjunt o Datos	Características Seleccionadas	# gens	Entrenamiento		Prueba	
			Exa c	Tiempo	Acc	Time
20	['beta_F8', 'theta_FZ', 'alpha_CP1', 'alpha_F4', 'delta_CP2', 'beta_C4', 'delta_F3', 'delta_P8']	8	55.64	117.6534	60.00	0.1706
40	['beta_PO3', 'delta_P7', 'theta_CP2', 'beta_FC6', 'alpha_T8', 'alpha_CP2', 'alpha_P7', 'theta_AF4', 'theta_FC6', 'theta_F8', 'delta_F4', 'alpha_PO1', 'alpha_C4', 'alpha_PO4', 'theta_F7', 'theta_F3', 'delta_T7', 'beta_FP2', 'alpha_CP6', 'delta_OZ', 'theta_C3', 'beta_PO1', 'beta_F7']	23	55.72	171.3273	71.60	0.8879
60	['beta_CP2', 'theta_PO4', 'delta_P8', 'theta_F7', 'theta_F4', 'alpha_P4', 'theta_FC1', 'alpha_T7', 'delta_F3', 'alpha_CP6', 'beta_P8', 'delta_F4', 'delta_AF4', 'beta_PO1', 'beta_FZ', 'beta_FC2', 'beta_FC1', 'beta_F8', 'theta_PZ', 'delta_FC6', 'alpha_F8', 'delta_CP2', 'alpha_FC3', 'delta_CP6', 'theta_P4']	25	55.80	170.5360	69.53	0.8928
80	['beta_F4', 'beta_F3', 'alpha_CP6', 'delta_PZ', 'delta_AF4', 'theta_CP1', 'delta_CZ', 'alpha_P4', 'delta_FP2', 'delta_T8', 'theta_FP2', 'theta_C4', 'delta_T7', 'theta_PO1', 'beta_CP5', 'beta_P7', 'alpha_PO1', 'theta_PZ', 'alpha_O2', 'theta_FZ', 'beta_CP2', 'theta_T7', 'delta_PO4', 'theta_CP6', 'theta_T8', 'alpha_P3', 'theta_F4', 'beta_PO4', 'delta_CP2', 'theta_O2', 'beta_FC1', 'delta_PO1', 'beta_F7', 'delta_FC5', 'alpha_C4', 'beta_FC2', 'theta_P3', 'theta_CP5', 'theta_PO3', 'delta_CP1']	40	55.74	224.8113	70.93	1.1032
100	['delta_CZ', 'alpha_T7', 'theta_FZ', 'theta_P8', 'beta_F4', 'theta_FC5', 'beta_CP1', 'theta_F7', 'theta_OZ', 'theta_P4', 'theta_FP2', 'delta_F3', 'alpha_F7', 'beta_T7', 'alpha_P7', 'theta_CP1', 'alpha_FC5', 'alpha_O2', 'delta_AF4', 'delta_CP2', 'delta_FC2', 'alpha_P4', 'beta_FP2', 'beta_CZ', 'theta_C4', 'delta_FC5', 'alpha_F8', 'theta_T8', 'theta_PZ', 'alpha_CZ', 'theta_PO4', 'delta_PO4', 'theta_CP5', 'beta_C4', 'theta_PO3', 'delta_CP5', 'alpha_PO1', 'beta_PZ', 'delta_F8', 'beta_FC5', 'beta_AF4', 'delta_P4', 'theta_FC1', 'alpha_FZ', 'theta_O2', 'alpha_P8', 'theta_F8']	43	55.82	252.3705	71.48	1.4938
120	['beta_P8', 'beta_O2', 'beta_AF4', 'alpha_CP2', 'beta_P3', 'delta_P7', 'theta_FP2', 'beta_FC1', 'beta_PO1', 'theta_P8', 'theta_P7', 'delta_FP2', 'alpha_C4', 'theta_PO3', 'delta_F3', 'alpha_CP6', 'alpha_FP2', 'beta_PZ', 'beta_CZ', 'alpha_FZ', 'alpha_CP5', 'delta_C4', 'delta_O2', 'delta_F8', 'beta_F3', 'theta_FZ', 'theta_C3', 'alpha_F7', 'alpha_CZ', 'alpha_P8', 'alpha_O2', 'beta_F4', 'theta_O2', 'beta_FZ', 'theta_CP5', 'theta_CP2', 'delta_FC5', 'delta_F7', 'alpha_P4', 'theta_FC6', 'theta_T7', 'beta_P4', 'delta_FC6', 'delta_FC1', 'theta_F3', 'beta_PO3', 'alpha_T7', 'theta_P4', 'theta_F4', 'delta_CP1', 'theta_FC1', 'beta_FP2', 'beta_F8', 'alpha_AF4', 'beta_T7', 'theta_CZ', 'beta_FC5', 'alpha_FC5', 'beta_FC2', 'delta_F4']	60	55.78	234.6819	73.14	1.5008
<b>Total</b>			55.75	195.2300	69.44	1.0081

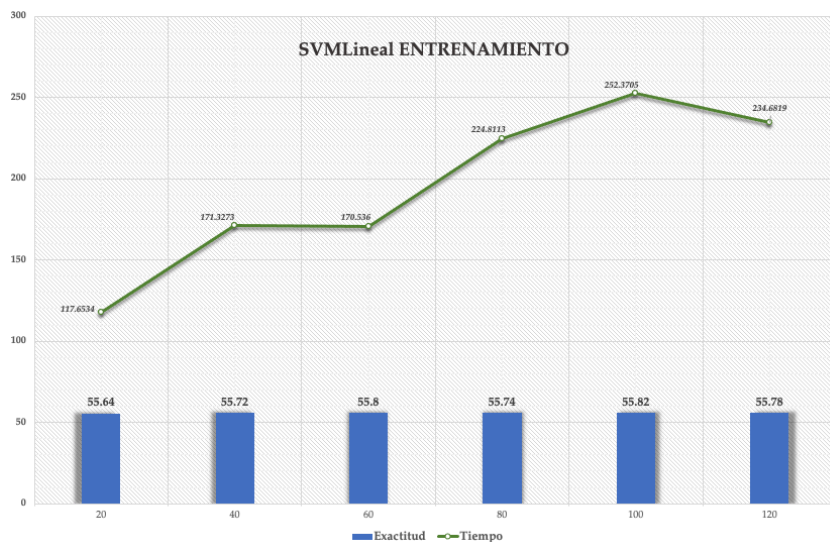


Figura 35 Análisis del desempeño del GALoRSI-SVMLineal en la fase de entrenamiento



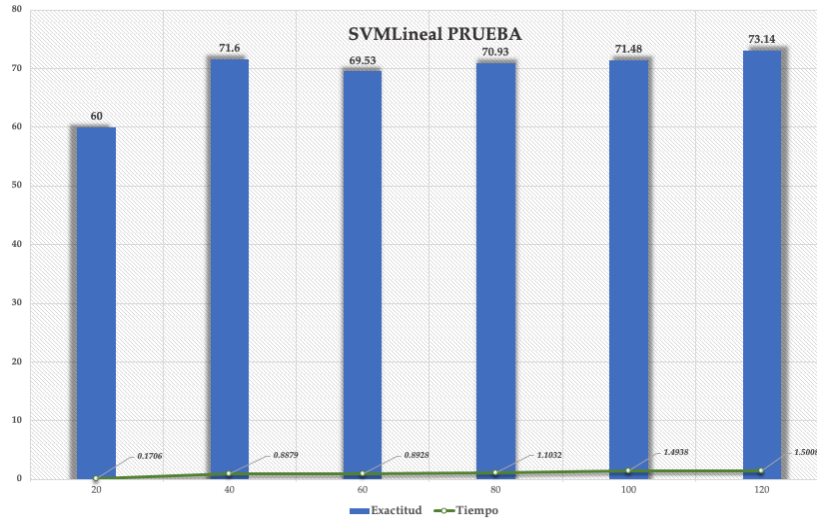


Figura 36 Análisis del desempeño del GALoRSI-SVMLineal en la fase de prueba

### 4.3. Resultados de k-NN

En la Tabla 21 se presenta los resultados obtenidos al evaluar GALoRSI utilizando el algoritmo k-NN. Como se observa, el conjunto de datos de 20 características obtuvo el mejor resultado en las fases de entrenamiento y prueba del modelo con una tasa de exactitud al clasificar los datos de 79.14% y 86.96%. Seguido del conjunto con 80 características con una exactitud del 76.71% y 83.15%. El conjunto de 100 características obtuvo un 76.64% y 83.17%. El conjunto de 120 características obtuvo un 76.56% y 81.84%. El conjunto con 40 características obtuvo un 76.34% y 81.28%. Finalmente, el conjunto con 60 características obtuvo una tasa de exactitud del 76.30% y 82.49%.

El modelo logró en promedio un tiempo de procesamiento de 213.41s y 0.18s en las fases de entrenamiento y prueba reduciendo el tiempo en un 99%.

En la Figura 37 y Figura 38 se presenta el análisis de la tasa de desempeño y el tiempo de procesamiento obtenido en cada conjunto de datos durante las fases de entrenamiento y prueba utilizando el algoritmo k-NN. Como se observa en la Figura 37 a medida que fue incrementando el tamaño de características fue incrementando en promedio 45s el tiempo de procesamiento entre cada conjunto sin incrementar significativamente la tasa de exactitud del modelo. Por otro lado, en la Figura 38 se observa que en la fase de prueba el tiempo de procesamiento entre cada conjunto incremento en promedio un 0.006s, logrando una tasa de exactitud de hasta el 86.96%.

### 4.4. Resultados de RL

En la Tabla 22 se presentan los resultados obtenidos al implementar el algoritmo RL en el modelo propuesto. Como se observa, el conjunto de datos con 120 características obtuvo el mejor resultado en las fases de entrenamiento y prueba del modelo con una tasa de exactitud al clasificar los datos de 57.40% y 62.71%. Seguido del conjunto con 80 características con una exactitud del 57.01% y 61.09%. El conjunto con 100 características obtuvo un 56.75% y 61.73%. El conjunto con 20 características obtuvo un 56.58% y 58.37%. El conjunto con 40 características logró un 56.52% y 60.37%. Finalmente, el conjunto con 60 características obtuvo una tasa de exactitud del 56.28% y 60.27%.

Tabla 21 Resultados obtenidos de evaluar el modelo GALoRSI utilizando k-NN

Conjunto Datos	Características Seleccionadas	# gens	Entrenamiento		Prueba	
			Exac	Tiempo	Acc	Exac
20	['theta_P7', 'alpha_PO1', 'beta_PO1', 'delta_AF4', 'delta_PO4', 'delta_PZ', 'alpha_FP2', 'alpha_FC3', 'alpha_F3', 'delta_CP5', 'delta_OZ']	11	79.14	101.2912	86.96	0.1991
40	['beta_PO3', 'delta_C4', 'beta_T8', 'beta_FC5', 'theta_P3', 'beta_F8', 'beta_CP2', 'alpha_FP2', 'beta_CZ', 'delta_F4', 'beta_FC1', 'theta_T8', 'thetaFC1', 'beta_O2', 'theta_CZ', 'beta_PZ', 'beta_PO3', 'theta_FC6', 'thetaF7', 'alpha_CZ', 'delta_PO1']	21	76.34	163.2046	81.28	0.2128
60	['beta_FC2', 'theta_PO4', 'delta_P4', 'alpha_FC3', 'alpha_CP5', 'alpha_OZ', 'theta_FC6', 'delta_PO1', 'theta_FP2', 'beta_P7', 'alpha_C4', 'alpha_FP2', 'alpha_F7', 'theta_CP5', 'alpha_T7', 'theta_F8', 'alpha_FC5', 'alpha_CP1', 'theta_P8', 'beta_FC6', 'beta_PO3', 'theta_FZ', 'beta_F3', 'beta_PZ', 'delta_CP2', 'alpha_F8', 'theta_CZ', 'beta_PO1', 'beta_FZ', 'delta_FC2', 'beta_CP2', 'theta_CP6', 'delta_OZ', 'delta_CP6', 'beta_P4']	35	76.30	194.5399	82.49	0.1510
80	['delta_PO4', 'alpha_FZ', 'beta_P4', 'alpha_FP2', 'theta_P3', 'beta_F3', 'theta_FC2', 'delta_C4', 'beta_O2', 'alpha_C4', 'alpha_O2', 'delta_C3', 'delta_PO3', 'alpha_F8', 'delta_P4', 'delta_F7', 'theta_PO4', 'beta_T7', 'delta_O2', 'beta_FC5', 'delta_FC2', 'delta_OZ', 'alpha_FC1', 'theta_O2', 'delta_P7', 'beta_FC6', 'beta_C3', 'theta_FZ', 'delta_CP5', 'theta_C4', 'theta_FC6', 'delta_CP1', 'beta_OZ', 'alpha_F3', 'theta_CZ', 'delta_CP6', 'alpha_CP1', 'beta_F7', 'alpha_FC5', 'delta_AF4', 'alpha_PO1']	41	76.71	229.3889	83.15	0.1285
100	['delta_OZ', 'delta_T7', 'delta_FC2', 'theta_CP1', 'theta_FP2', 'theta_PO4', 'alpha_OZ', 'beta_PZ', 'beta_P4', 'beta_CP1', 'theta_FC6', 'theta_CZ', 'theta_FZ', 'alpha_CP6', 'beta_P8', 'delta_O2', 'alpha_P3', 'alpha_AF4', 'alpha_P4', 'alpha_C4', 'beta_O2', 'delta_T8', 'theta_F8', 'beta_FC1', 'alpha_F7', 'alpha_P7', 'beta_T7', 'alpha_FC5', 'delta_CP2', 'alpha_PO3', 'delta_CP6', 'alpha_CZ', 'delta_CP1', 'alpha_F4', 'theta_C3', 'delta_PZ', 'beta_C3', 'theta_CP6', 'alpha_PO1', 'theta_O2', 'beta_AF4', 'thetaFC1', 'beta_C4', 'delta_FP2', 'delta_PO1', 'beta_PO3']	46	76.64	261.5976	83.17	0.1774
120	['delta_P3', 'alpha_T8', 'theta_AF4', 'theta_CP5', 'delta_F3', 'beta_CP1', 'beta_P7', 'delta_PO1', 'delta_OZ', 'beta_FC2', 'alpha_P4', 'alpha_FC1', 'theta_PO1', 'beta_T7', 'delta_O2', 'alpha_FZ', 'beta_C4', 'beta_FZ', 'delta_C3', 'delta_CP5', 'theta_P4', 'theta_FC2', 'alpha_P7', 'alpha_AF4', 'theta_C3', 'theta_CP1', 'alpha_F4', 'beta_PO4', 'beta_CZ', 'delta_FZ', 'delta_AF4', 'theta_T7', 'delta_P4', 'theta_P8', 'alpha_PO1', 'delta_P8', 'beta_AF4', 'delta_CP2', 'beta_CP5', 'alpha_FC5', 'theta_F3', 'beta_P4', 'beta_OZ', 'theta_FZ', 'beta_F3', 'delta_FC6', 'theta_CP6', 'thetaFC5', 'alpha_O2', 'beta_F4', 'beta_C3', 'theta_P7', 'alpha_CP1', 'beta_O2', 'thetaF7', 'theta_CZ', 'delta_CZ', 'alpha_FP2', 'alpha_F7', 'delta_PO3', 'delta_C4', 'alpha_T7']	62	76.56	330.4624	81.84	0.2294
<b>Total</b>			76.94	213.4141	83.14	0.1830

El modelo logró en promedio un tiempo de procesamiento de 179.49s y 0.22s en las fases de entrenamiento y prueba reduciendo el tiempo en un 99%.

En la Figura 39 y Figura 40 se presenta el análisis de la tasa de desempeño y el tiempo de procesamiento obtenido en cada conjunto de datos durante las fases de entrenamiento y prueba de RL. Como se observa en la Figura 39, a medida que fue incrementando el tamaño de características, fue incrementando en promedio 32s el tiempo de procesamiento entre cada conjunto sin incrementar significativamente la tasa de exactitud del modelo. Por otro lado, en la Figura 40 se observa que en la fase de prueba el tiempo de procesamiento entre cada conjunto incremento en promedio un 0.09s, incrementando con ello la tasa de exactitud de hasta el 62.71%.



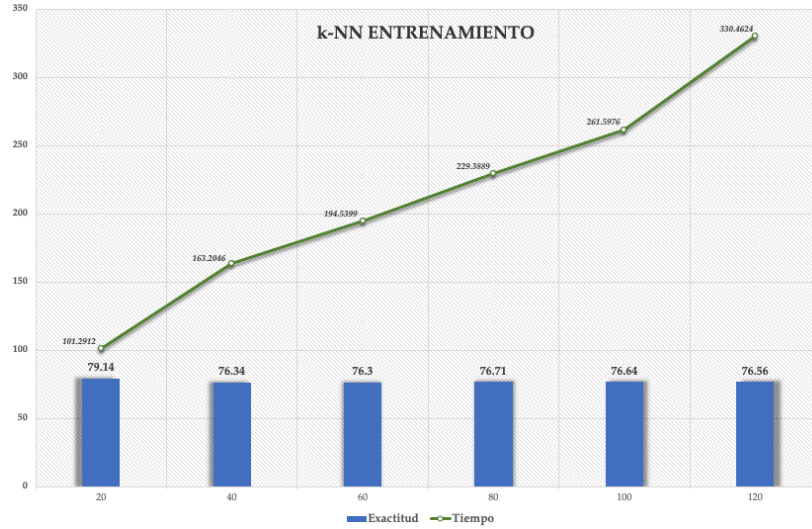


Figura 37 Análisis del desempeño del GALoRSI-k-NN en la fase de entrenamiento

Tabla 22 Resultados obtenidos de evaluar el modelo GALoRSI utilizando RL

Conjunt o Datos	Características Seleccionadas	# gen s	Entrenamiento		Prueba	
			Exac	Tiempo	Exac	Tiempo
20	['theta_FZ', 'theta_AF4', 'beta_CZ', 'theta_P01', 'delta_F8', 'alpha_P8', 'alpha_F3', 'alpha_FC1', 'beta_PO4', 'alpha_FP2']	10	56.58	116.8444	58.37	0.1060
40	['delta_FZ', 'alpha_T8', 'beta_AF4', 'theta_CP5', 'delta_P3', 'delta_FP2', 'theta_FZ', 'theta_T8', 'beta_CP5', 'beta_CP2', 'alpha_CP5', 'delta_CZ', 'theta_FC2', 'beta_P7', 'delta_P4', 'delta_T8', 'delta_CP5', 'alpha_CP2', 'beta_CP6', 'delta_P7']	20	56.52	154.1331	60.37	0.1272
60	['theta_P3', 'alpha_P8', 'theta_O2', 'theta_FC5', 'beta_C3', 'alpha_FC1', 'alpha_PO4', 'alpha_F4', 'beta_P3', 'theta_PO4', 'alpha_PO1', 'beta_F7', 'delta_T7', 'beta_FC5', 'beta_CP1', 'theta_P01', 'delta_F8', 'theta_FZ', 'delta_CZ', 'alpha_F3', 'delta_CP5', 'theta_PZ', 'delta_AF4', 'beta_FZ', 'delta_PZ', 'alpha_CP2', 'beta_P7', 'delta_F4', 'beta_AF4', 'beta_FC6', 'beta_FC2', 'delta_T8', 'beta_F4', 'theta_F3']	34	56.38	177.4707	60.27	0.2684
80	['beta_CP6', 'alpha_F7', 'delta_FC6', 'beta_FP2', 'delta_F8', 'delta_F3', 'beta_CP2', 'theta_P03', 'delta_CZ', 'theta_FP2', 'delta_F7', 'theta_P8', 'alpha_AF4', 'delta_CP5', 'alpha_P4', 'alpha_FC2', 'delta_AF4', 'delta_T8', 'theta_CP5', 'alpha_PZ', 'alpha_FC6', 'alpha_FZ', 'theta_P7', 'theta_FC6', 'delta_C4', 'alpha_FC5', 'delta_PO4', 'delta_FC5', 'alpha_FC1', 'delta_F4', 'theta_CP1', 'delta_P4', 'theta_F3', 'delta_O2', 'beta_F3']	35	57.01	206.7524	61.09	0.2105
100	['theta_F3', 'beta_P8', 'theta_P01', 'theta_PO4', 'beta_C4', 'alpha_PO3', 'delta_PZ', 'delta_T7', 'alpha_FC5', 'beta_PO1', 'delta_P3', 'beta_F3', 'alpha_FZ', 'theta_FC1', 'alpha_F3', 'alpha_CP6', 'alpha_T8', 'delta_F4', 'theta_AF4', 'beta_CP6', 'alpha_CP5', 'beta_F4', 'alpha_C4', 'delta_F8', 'delta_FC1', 'alpha_AF4', 'theta_OZ', 'theta_C4', 'theta_O2', 'beta_CP5', 'beta_T8', 'delta_P4', 'alpha_PZ', 'alpha_O2', 'beta_P3', 'delta_P8', 'beta_F7', 'theta_P3', 'alpha_P4', 'delta_CP5', 'beta_P7', 'alpha_FP2', 'alpha_PO4', 'delta_C3', 'delta_T8', 'beta_FP2', 'beta_PO4', 'alpha_T7', 'theta_CP5', 'theta_FC2', 'beta_F8']	51	56.75	241.5755	61.73	0.3586
120	['alpha_FC3', 'alpha_P4', 'theta_FC5', 'alpha_T8', 'delta_FC2', 'delta_CP5', 'delta_CP1', 'theta_PO4', 'theta_O2', 'theta_P03', 'alpha_CZ', 'theta_F7', 'beta_FC2', 'delta_AF4', 'delta_FP2', 'theta_T7', 'alpha_CP2', 'theta_CZ', 'beta_CP5', 'theta_P7', 'beta_P3', 'delta_FC5', 'alpha_CP6', 'delta_P8', 'delta_CP6', 'theta_OZ', 'beta_T8', 'delta_C4', 'beta_FC5', 'delta_PO4', 'beta_C4', 'theta_CP2', 'beta_F4', 'alpha_PO4', 'delta_PO1', 'delta_CZ', 'theta_F4', 'beta_CP6', 'alpha_FC6', 'delta_P3', 'beta_FP2', 'alpha_FC5', 'beta_AF4', 'theta_CP1', 'alpha_FP2', 'beta_F3', 'theta_FC6', 'delta_OZ', 'alpha_P7', 'theta_FP2', 'beta_P8', 'delta_O2', 'delta_P4', 'theta_P01', 'alpha_P8', 'beta_F8', 'theta_FC2', 'alpha_O2', 'delta_T8', 'alpha_FC1', 'theta_PZ', 'theta_CP5', 'alpha_P3']	63	57.40	280.2221	62.71	0.2499
<b>Total</b>			56.77	179.4997	60.75	0.2201




Figura 38 Análisis del desempeño del GALoRSI-k-NN en la fase de prueba

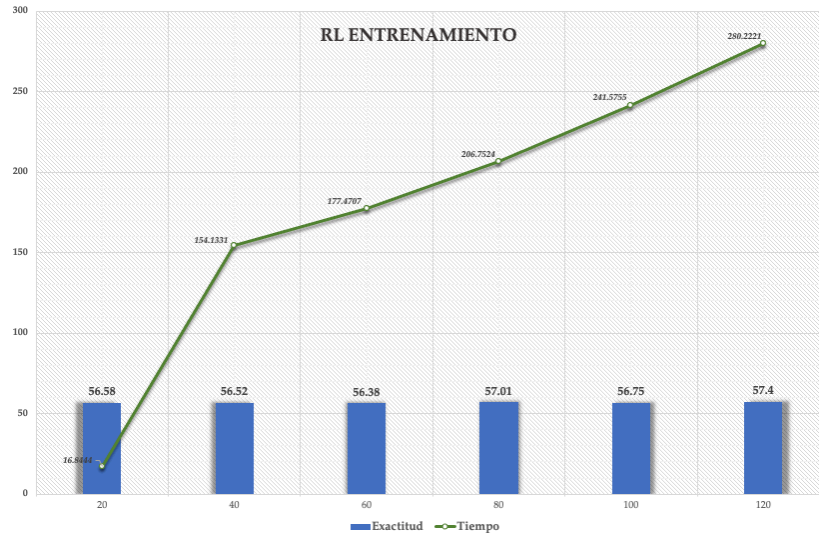


Figura 39 Análisis del desempeño del GALoRSI-RL en la fase de entrenamiento

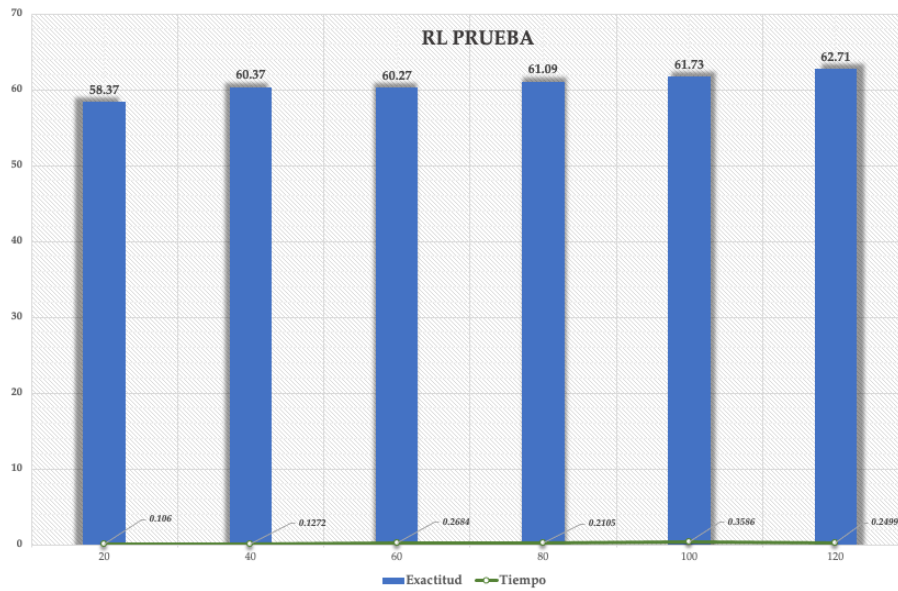


Figura 40 Análisis del desempeño del GALoRSI-RL en la fase de prueba

#### 4.5. Resultados de la Exactitud

En la literatura, se han propuesto investigaciones relacionadas a este trabajo enfocadas en el desarrollo de modelos capaces de identificar patrones en DEAP con el objetivo de crear modelos de predicciones con mayor tasa de exactitud como se muestra en la Figura 41. A continuación, se presentan los trabajos más destacados en los recientes años.

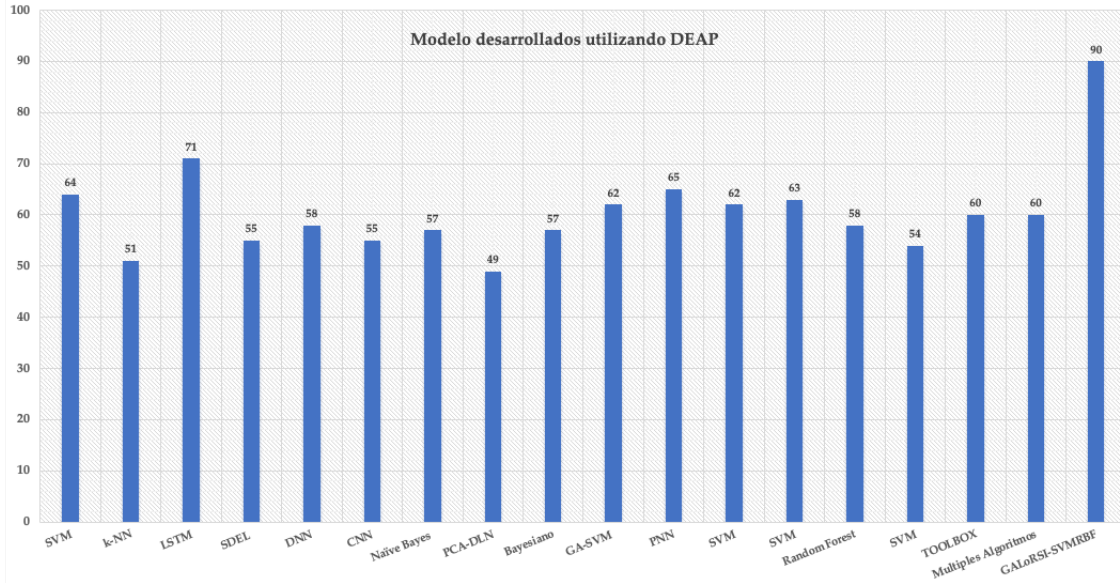


Figura 41 Comparación de modelos de predicción desarrollados con DEAP

En [194] desarrollaron un modelo de predicciones basado en SVM utilizando los canales Fp1, Fp2, F3, F4, T7, T8, P3, P4, O1, y O2 con la información extraída de theta (4-8 Hz), alfa (8-12 Hz), beta (13-30 Hz), y gamma (30-45 Hz) logrando un resultado de precisión del 64.9%. En [193] proponen un modelo basado en k-NN utilizando la información de 18 canales (8 IzqCh, 8 DerCh, 1 CentralCh, 1 VirtualC) logrando una tasa de predicción del 51.01%. En [196] utilizaron 96 características implementando LSTM (Long-Short Term Memory) obteniendo un 71% de precisión en la clasificación. En [190] desarrollaron un modelo basado en SDEL (Sparse Discriminative Ensemble Learning) para discriminar y clasificar la información obteniendo un 55% identificando 40 canales relevantes. En [197] utilizaron la información de 40 canales implementando DNN (Deep Neural Network) y CNN (Convolutional Neural Network) logrando un 58.44% y 55.70%. En [169] desarrollaron un modelo implementando SVM logrando un 59%. En [116] proponen un modelo basado en Naïve Bayes obteniendo un 57% utilizando todos los canales. En [74] extrajeron 50 de 230 características EEG utilizando PCA (Principal Component Analysis) y DLN (Deep Learning Network) obteniendo como resultado 49.52% de precisión. En [198] utilizaron 392 características implementando un clasificador bayesiano obteniendo un 57%. En [199] implementaron mRMR (minimum- Redundancy-Maximum-Relevance) y GA-SVM para seleccionar y clasificar la información obteniendo un 60.72% y 62.4% identificando 35 y 20 características como relevantes. En [97] utilizaron PSO y GA para seleccionar las

características FP1, F7, FC5, AF4, CP6, PO4, O2, T7 y T8 e implementaron PNN (Probabilistic neural network) para clasificar la información logrando un 65%. En [200] utilizaron la información de 3 y 5 bandas de 18 y 32 canales utilizando SVM logrando un 60%. En [201] utilizaron 22 características con SVM logrando un 62%. En [195] utilizaron las bandas delta, theta, alfa y beta de los canales Fp1, Fp2, F3 y F4 implementando SVM y Random Forest logrando un 63.1% y 58.8%. En [202] utilizaron las características extraídas por wavelet y SVM obteniendo un 54%. En [203] implementan un algoritmo denominado Toolbox para extraer las características EEG logrando un 60%. En [204] utilizaron la información de las bandas theta, alfa, beta y gamma implementando múltiples algoritmos de aprendizaje supervisado obteniendo en promedio un 60%. GALoRSI- SVMRBF obtuvo una tasa máxima de exactitud al clasificar los datos del 89.45% y 90.21% en las fases de entrenamiento y prueba.

#### 4.6. Resultados del Tiempo de Procesamiento

En la Tabla 23 se presenta el análisis del tiempo de procesamiento de algunos trabajos relacionados a esta investigación. En [85] utilizan el algoritmo MKL-SVM para analizar la información de 18 canales en un tiempo de 20.47s logrando una tasa de clasificación del 85%. En [162] utilizan SVM para analizar la información de 42 canales en un tiempo de 1.5s logrando una tasa de clasificación del 75%. En [64] utilizan SCSP2 para analizar la información de 8 canales en un tiempo de 50.1s obteniendo una tasa de clasificación del 79%. En [205] utilizan AG para analizar la información de 1 canal en un tiempo de 60s. En [206] implementan redes complejas para analizar la información de 4 canales en un tiempo de 45s logrando una tasa de clasificación del 92%. En [207] implementan LVQ para analizar la información de 4 canales en un tiempo de 706s logrando una tasa de clasificación del 85%.

Los algoritmos mencionados anteriormente tardan en promedio 147s en procesar la información de 12 canales aprox., con una tasa de clasificación del 65% donde si estos algoritmos analizan la información de 32 canales, tomarían un tiempo promedio de 396.9s en procesar los datos. GALoRSI procesa la información de 30 canales, es decir, la información de 120 características en un tiempo promedio de 180s logrando una tasa de clasificación del 69.73% durante la fase de entrenamiento y un tiempo promedio de 0.92s durante la fase de prueba logrando un 76.35% en la clasificación de los datos.

Tabla 23 Tiempo de Procesamiento de los Algoritmos utilizando las señales EEG

Referencia	Muestras/Canales	Algoritmo	Tiempo (s)	Exactitud
[85]	18 canales	MKL-SVM	20.47s	85%
[162]	42 canales	SVM	1.5s	75%
[64]	8/7 canales	SCSP2	50.1s	79%
[205]	1 canal	AG	60 s	-
[206]	4 canales	Complex Networks	45s	92%
[207]	4 canales	LVQ	706s	85%

En la Figura 42 y Figura 43 se muestra el tiempo promedio que tardaron los modelos en analizar cada conjunto de datos durante las fases de entrenamiento y prueba. En la Figura 42, se observa que, en la fase de entrenamiento, el tiempo de procesamiento del modelo fue incrementando en promedio 31s entre cada conjunto de datos logrando un tiempo de entre 99.92s hasta 258.57s en procesar los datos de 20-120 características.

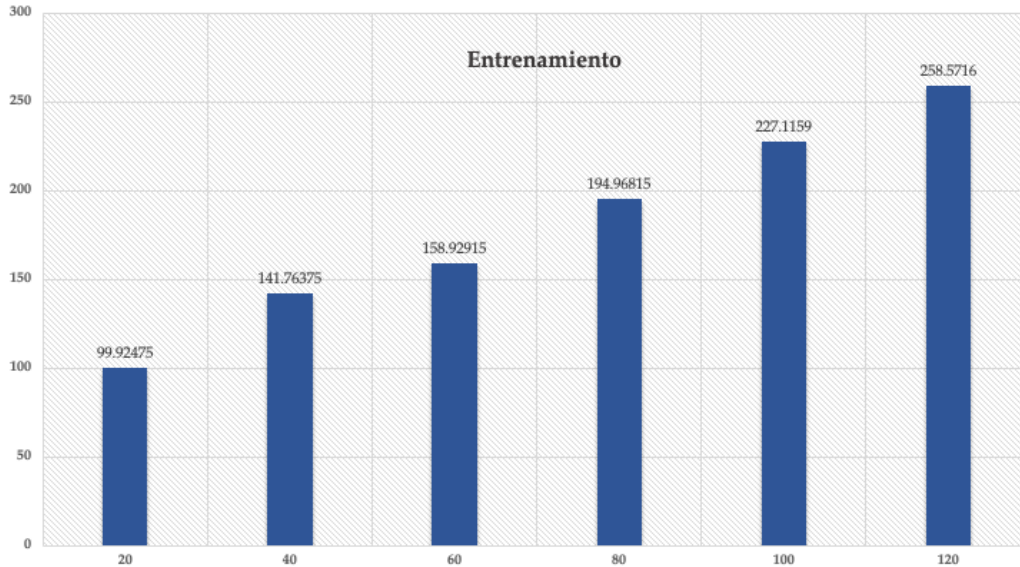


Figura 42 Tiempo de procesamiento en fase de entrenamiento

En la Figura 43, se observa que en la fase de prueba el tiempo promedio para el análisis de cada conjunto de datos fue de 0.21s. El conjunto con 20 características logró el menor tiempo de procesamiento con 0.54s. El conjunto con 100 características logró el mayor tiempo con 1.28s en procesar los datos.

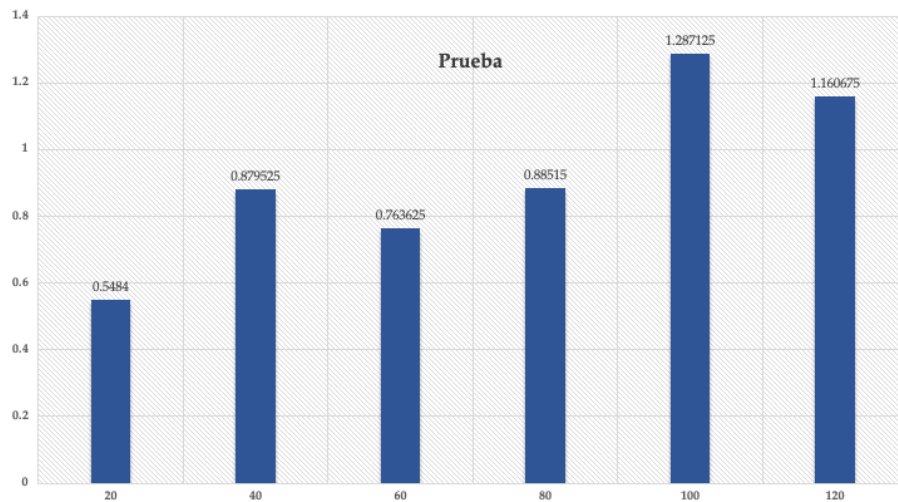


Figura 43 Tiempo de procesamiento en fase de prueba

#### 4.7. Resultados del Escalabilidad

En la Figura 44 se presenta el promedio de la tasa de exactitud de cada conjunto de datos durante las fases de entrenamiento y prueba. Se observa, que el conjunto con 80 características obtuvo el mejor desempeño en las fases de entrenamiento y prueba, logrando una tasa de exactitud de 69.73% y 76.35%. También, se observó que el tiempo requerido con 80 características en las dos fases fue mejor al compararlo con otros conjuntos. Por otro lado, los conjuntos de 100 y 20 características logran las tasas de exactitud más bajas con un 64.94% y 72.56% durante el entrenamiento y prueba del modelo.

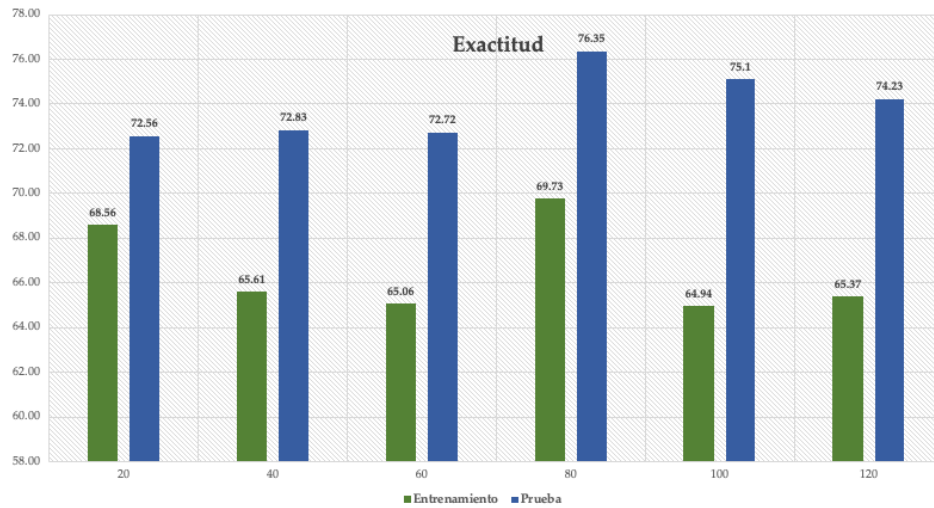


Figura 44 Tasa de exactitud por conjunto de datos

## 5. CONCLUSIONES

Los resultados obtenidos al analizar el desempeño de GALoRSI-SVMRBF utilizando DEAP, se demostró que los algoritmos de selección de características reducen el tiempo de procesamiento y la carga computacional algorítmica, mejorando el desempeño del modelo e incrementando la tasa de predicción. Se observó que GALoRSI-SVMRBF soporta conjuntos de datos que van desde 20 a 120 características obteniendo el mejor desempeño al analizar en promedio 80 características como datos de entrada.

Además, se observó que GALoRSI-SVMRBF puede ser entrenado en modo desconectado (offline) e implementarlo en un entorno de tiempo real sin afectar su desempeño debido a que GALoRSI-SVMRBF es capaz de realizar predicciones de estados emocionales en menos de 1.28s en la fase de prueba.

El tiempo de procesamiento que tarda GALoRSI-SVMRBF es aceptable considerando su implementación en un entorno de tipo redes V2V (Vehicle-to-Vehicle), V2I (Vehicle-to-Infrastructure) y I2I (Infrastructure-to-Infrastructure) donde la tasa máximo de tiempo de retardo para transmitir un mensaje es de 5s [208]. Esto permitirá notificar con antelación la presencia de alta o baja carga cognitiva a los conductores y sus acompañantes que podrán ser reflejadas como un incremento en la climatización del coche, mandar alertas a los coches



vecinos o en casos extremos avisar a tráfico del estado del conductor con el objetivo de evitar accidentes a diferentes niveles.

El análisis de la complejidad, escalabilidad y tiempo de procesamiento de los modelos predictivos utilizando señales EEG son investigaciones poco desarrolladas que serían temas de interés para futuros trabajos de investigación.





# CAPÍTULO VII

## CONCLUSIONES Y TRABAJOS FUTUROS

En este capítulo se presentan las conclusiones generales de este proyecto de tesis basadas en la problemática, hipótesis y objetivos definidos. Además, se presentan los trabajos futuros propuestos de esta investigación.

### 1. CONCLUSIONES DE LA TESIS

A continuación, se presentan las respuestas a las preguntas de investigación realizadas en la sesión de introducción.

- ¿Las señales EEG pueden ser utilizadas para predecir la carga cognitiva baja y alta de los conductores de vehículos de manera eficiente?

En este estudio fue analizada la actividad de las bandas de frecuencia de la señal EEG recolectada de los sujetos durante la conducción de un vehículo. Se observó que a medida que aumentaba la dificultad en la tarea, incrementaba la actividad de las bandas alfa, beta y gamma. Así mismo, la actividad en las bandas delta y theta disminuye. Este comportamiento se debe a que cada banda está relacionada a un estado cognitivo.

Además, estos resultados permitieron concluir que los sujetos al incrementar la demanda de la carga cognitiva se ven afectada su concentración e incrementa los errores durante la conducción.

Es importante mencionar que el análisis de una señal EEG específica no puede ser utilizada para identificar con precisión estados cognitivos, debido al alto nivel de ruido y artefactos que genera la señal. También, se observó que la fase de diseño, recolección y experimentación de los datos EEG son fundamentales en el desarrollo de los modelos de predicción, debido a que sus resultados dependen de la información recolectada. Aplicar una mala técnica de recolección de los datos implica un entrenamiento erróneo del modelo y por lo tanto predicciones desfasadas de la realidad.

- ¿Se pueden determinar características claves de las señales EEG que describan los estados de baja y alta carga cognitiva de las personas durante la conducción de un vehículo?

Para abordar esta pregunta, en esta tesis se investigaron diferentes enfoques para tratar la información EEG, tales como la combinación, fusión y selección de los datos de una o múltiples fuentes para analizar la clasificación de los datos y optimizar la fase de entrenamiento del clasificador.

En específico, en el capítulo III se analizó la influencia de la actividad de las bandas de frecuencia con los estados cognitivos y basado en eso se desarrolló un método de agrupación de los datos donde se encontró que  $\theta$ ,  $\delta$  y  $\theta + \alpha/\beta$  contienen información relevante que permite distinguir entre el estado de baja y alta carga cognitiva.

Por otro lado, en el capítulo IV se propone un análisis de la información EEG desarrollando una técnica de selección de características basada en algoritmos genéticos, regresión logística y técnicas estadísticas. La información fue organizada en siete grupos para analizar no sólo las características, sino también, la influencia entre ellas donde se identificaron subconjuntos de datos que contienen información que permite describir un estado cognitivo. Con los resultados obtenidos, se observó que los conjuntos que contienen información de las bandas alfa y beta pueden identificar con mayor precisión el estado cognitivo bajo y alto. Por otro lado, se observó que al analizar las características Delta\_F7, Alfa\_AF4, Alfa\_F3, Alfa\_F7, Alfa\_F8, Alfa\_O2, Alfa\_P8, Beta\_AF4 y Beta\_FC5 contienen información relevante que pueden ser utilizada para identificar estados cognitivos.

Por último, en el capítulo VI se probó la eficiencia de la técnica de agrupación y selección de características para identificar información clave de las señales EEG utilizando una base de datos pública SEED-VIG. Se observó que el modelo propuesto identifica información EEG clave para el reconocimiento de patrones mejorando el rendimiento del modelo en un 20%.

Se concluye que las características EEG pueden ser utilizadas para describir un estado cognitivo en específico. Sin embargo, hasta la fecha no existe investigación que den soporte a la identificación de valores estándares que permitan definir el estado de la persona utilizando una banda específica. Es importante mencionar que en este estudio no se analizó la influencia de los electrodos y su localización, para ello se requiere un análisis exploratorio por separado.

- ¿Se puede desarrollar un modelo predictivo enfocado en la selección, estructuración y clasificación de los datos para optimizar el análisis de la información y el desempeño del modelo, enfrentando los principales problemas de las señales EEG?

En este estudio se diseñó la metodología del desarrollo de un modelo para predecir estados cognitivos enfocado en la estructuración y modelado de la información de las señales EEG. El modelo fue desarrollado en cuatro principales módulos los cuales son recolección y procesamiento de la señal, extracción de datos, selección de características y desarrollo del clasificador. La implementación de los cuatro módulos permitió construir un modelo de predicciones capaz de soportar información EEG de uno o múltiples canales eficientemente obteniendo un alto desempeño y una alta tasa de predicción.

## 2. TRABAJOS FUTUROS

Se ha desarrollado un modelo de predicciones de carga cognitiva basado en señales EEG utilizando algoritmos de AA y técnicas estadísticas. Sin embargo, los trabajos futuros derivados de esta tesis se describen a continuación:

- Uno de los principales trabajos futuros que se plantea a partir de esta investigación es la integración de nuevas medidas fisiológicas en el modelo, tales como, el movimiento ocular, la temperatura corporal y/o ritmo cardíaco con la finalidad de mejorar su eficiencia y sensibilidad al realizar predicciones más exactas del estado cognitivo de la persona.
- Se propone la integración de nuevas medidas subjetivas y de rendimiento como datos de entrada en el modelo de predicción.
- Otro de los trabajos futuros que se propone a partir de esta investigación es integrar en el modelo la predicción de más estados cognitivos de los sujetos al realizar actividades como la conducción de un vehículo.
- Por último, se propone profundizar en el análisis de las características EEG para determinar rangos que pueden ser utilizados como un estándar para la identificación de los estados cognitivos.

## 3. BASES DE DATOS DISPONIBLES

- La información utilizada en esta investigación se encuentra disponible en <https://github.com/patriciabcsa/EEGSignalDataBase>
- El conjunto de datos DEAP y SEED están disponibles en <https://www.eecs.qmul.ac.uk/mmv/datasets/deap/> y <http://bcmi.sjtu.edu.cn/~seed/seed-vig.html>. Cualquier persona interesada en utilizar estos conjuntos de datos deberá imprimir, firmar y escanear un acuerdo de licencia de usuario final y devolverlo por correo electrónico para obtener un nombre de usuario y contraseña que permitirá descargar los datos.

## 4. REPOSITARIOS

- El código desarrollado para construir las interfaces se encuentra disponible en <https://github.com/patriciabcsa/DataExtraccionInterfaces>
- El código desarrollado para construir GALoRSI-SVMRBF se encuentra disponible en <https://github.com/patriciabcsa/GALORSIRVMrbf>.

## REFERENCIAS

- [1] L. Ian Chen, Y. Zhao, P. fei Ye, J. Zhang, and J. zhong Zou, “Detecting driving stress in physiological signals based on multimodal feature analysis and kernel classifiers,” *Expert Syst. Appl.*, vol. 85, pp. 279–291, 2017, doi: 10.1016/j.eswa.2017.01.040.
- [2] F. Sagberg, Selpi, G. F. Bianchi Piccinini, and J. Engström, “A review of research on driving styles and road safety,” *Hum. Factors*, vol. 57, no. 7, pp. 1248–1275, 2015.
- [3] T. Qu, H. Chen, D. Cao, H. Guo, and B. Gao, “Switching-based stochastic model predictive control approach for modeling driver steering skill,” *IEEE Trans. Intell. Transp. Syst.*, vol. 16, no. 1, pp. 365–375, 2014.
- [4] L. Yan, Z. Huang, Y. Zhang, L. Zhang, D. Zhu, and B. Ran, “Driving risk status prediction using Bayesian networks and logistic regression,” *IET Intell. Transp. Syst.*, vol. 11, no. 7, pp. 431–439, 2017, doi: 10.1049/iet-its.2016.0207.
- [5] Dirección General de Tráfico, “DGT,” 2018. .
- [6] P. Becerra-s and A. Reyes-munoz, “Feature Selection Model Based on EEG Signals for Assessing the Cognitive Workload in Drivers,” 2020.
- [7] C. Jacobé de Naurois, C. Bourdin, A. Stratulat, E. Diaz, and J. L. Vercher, “Detection and prediction of driver drowsiness using artificial neural network models,” *Accid. Anal. Prev.*, vol. 126, no. October, pp. 95–104, 2019, doi: 10.1016/j.aap.2017.11.038.
- [8] S. M. Ko and Y. G. Ji, “How we can measure the non-driving-task engagement in automated driving: comparing flow experience and workload,” *Appl. Ergon.*, vol. 67, pp. 237–245, 2018.
- [9] S. Rubio-Valdehita, E. M. Díaz-Ramiro, R. López-Higes, and J. Martín-García, “Effects of task load and cognitive abilities on performance and subjective mental workload in a tracking task,” *An. Psicol.*, vol. 28, no. 3, pp. 986–995, 2012.
- [10] G. Rolo González, D. Díaz Cabrera, and E. Hernández Fernaud, “Desarrollo de una escala subjetiva de carga mental de trabajo (ESCAM),” *Rev. Psicol. del Trab. y las Organ.*, vol. 25, no. 1, pp. 29–37, 2009.
- [11] C. Nikulin, G. Lopez, E. Piñonez, L. Gonzalez, and P. Zapata, “NASA-TLX for predictability and measurability of instructional design models: Case study in design methods,” *Educ. Technol. Res. Dev.*, vol. 67, no. 2, pp. 467–493, 2019.
- [12] W. Wang, J. Xi, and H. Chen, “Modeling and recognizing driver behavior based on driving data: A survey,” *Math. Probl. Eng.*, vol. 2014, 2014, doi: 10.1155/2014/245641.
- [13] Z. Wei, D. Zhuang, X. Wanyan, C. Liu, and H. Zhuang, “A model for discrimination and prediction of mental workload of aircraft cockpit display interface,” *Chinese J. Aeronaut.*, vol. 27, no. 5, pp. 1070–1077, 2014, doi: 10.1016/j.cja.2014.09.002.
- [14] X. Li, W. Fang, and Y. Zhou, “Mental workload prediction model based on information entropy,” *Computer Assisted Surgery*, vol. 21. pp. 117–124, 2016, doi: 10.1080/24699322.2016.1240298.
- [15] G. Borghini *et al.*, “Quantitative Assessment of the Training Improvement in a Motor-Cognitive Task by Using EEG, ECG and EOG Signals,” *Brain Topogr.*, vol. 29, no. 1, pp. 149–161, 2016, doi: 10.1007/s10548-015-0425-7.
- [16] Y. Liu, H. Ayaz, and P. A. Shewokis, “Multisubject ‘learning’ for mental workload classification using concurrent EEG, fNIRS, and physiological measures,” *Front. Hum. Neurosci.*, vol. 11, p. 389, 2017.
- [17] P. Zhang, X. Wang, J. Chen, and W. You, “Feature weight driven interactive mutual information modeling for heterogeneous bio-signal fusion to estimate mental workload,” *Sensors (Switzerland)*, vol. 17, no. 10, 2017, doi: 10.3390/s17102315.
- [18] S. Wang, J. Gwizdka, and W. A. Chaovalitwongse, “Using wireless EEG signals to assess memory workload in the \$ n \$-back task,” *IEEE Trans. Human-Machine Syst.*, vol. 46, no. 3, pp. 424–435, 2015, doi: 10.1109/THMS.2015.2476818.
- [19] D. Rozado and A. Dunser, “Combining EEG with Pupillometry to Improve Cognitive Workload Detection,” *Computer (Long Beach, Calif.)*, vol. 48, no. 10, pp. 18–25, 2015, doi: 10.1109/MC.2015.314.
- [20] C. Mühl, C. Jeunet, and F. Lotte, “EEG-based workload estimation across affective contexts,” *Front. Neurosci.*, vol. 8, no. 8 JUN, pp. 1–15, 2014, doi: 10.3389/fnins.2014.00114.
- [21] H. S. Kim, Y. Hwang, D. Yoon, W. Choi, and C. H. Park, “Driver workload characteristics analysis using EEG data from an urban road,” *IEEE Trans. Intell. Transp. Syst.*, vol. 15, no. 4, pp. 1844–1849, 2014.
- [22] P. Zarjam, J. Epps, and N. H. Lovell, “Beyond Subjective Self-Rating: EEG Signal Classification of Cognitive Workload,” *IEEE Trans. Auton. Ment. Dev.*, vol. 7, no. 4, pp. 301–310, 2015, doi: 10.1109/TAMD.2015.2441960.
- [23] P. Arico, “Mental states monitoring through passive Brain-Computer Interface systems.” alma, 2014.
- [24] J. Gwizdka, “Distribution of cognitive load in Web search,” *J. Am. Soc. Inf. Sci. Technol.*, vol. 61, no. 11, pp. 2167–2187, 2010, doi: 10.1002/asi.21385.
- [25] J. L. Auflick, “Resurrecting driver workload metrics: a multivariate approach,” *Procedia Manuf.*, vol. 3,

- pp. 3160–3167, 2015.
- [26] J. M. Morales *et al.*, “Monitoring driver fatigue using a single-channel electroencephalographic device: A validation study by gaze-based, driving performance, and subjective data,” *Accid. Anal. Prev.*, vol. 109, no. September, pp. 62–69, 2017, doi: 10.1016/j.aap.2017.09.025.
- [27] J. Paxion, E. Galy, and C. Berthelon, “Mental workload and driving,” *Front. Psychol.*, vol. 5, p. 1344, 2014.
- [28] S. Yan, C. C. Tran, Y. Wei, and J. L. Habiyaremye, “Driver’s mental workload prediction model based on physiological indices,” *Int. J. Occup. Saf. Ergon.*, vol. 0, no. 0, pp. 1–9, 2017, doi: 10.1080/10803548.2017.1368951.
- [29] J. A. Blanco *et al.*, “Quantifying cognitive workload in simulated flight using passive, dry EEG measurements,” *IEEE Trans. Cogn. Dev. Syst.*, vol. 10, no. 2, pp. 373–383, 2018, doi: 10.1109/TCDS.2016.2628702.
- [30] B. Y. M. Lobato and A. A. Garza, “Classification algorithm for measuring human emotion: "I like it" and "I do not like" in Neuromarketing,” *IEEE Lat. Am. Trans.*, vol. 15, no. 11, pp. 2177–2184, 2017.
- [31] L. Cao, J. Li, Y. Xu, H. Zhu, and C. Jiang, “A Hybrid Vigilance Monitoring Study for Mental Fatigue and Its Neural Activities,” *Cognit. Comput.*, vol. 8, no. 2, pp. 228–236, Apr. 2016, doi: 10.1007/s12559-015-9351-y.
- [32] R. P. Loreto and A. D. Carolina, “Aporte de los distintos métodos electroencefalográficos (eeg) al diagnóstico de las epilepsias,” *Rev. Médica Clínica Las Condes*, vol. 24, no. 6, pp. 953–957, 2013.
- [33] Y. Yu, N. Li, Y. Li, and W. Liu, “A Portable Waterproof EEG Acquisition Device for Dolphins,” *Sensors*, vol. 21, no. 10, p. 3336, 2021.
- [34] S. Murugappan, M., & Murugappan, “Human Emotion Recognition Through Short Time Electroencephalogram (EEG) Signals Using Fast Fourier Transform (FFT),” *IEEE 9th Int. Colloq. Signal Process. its Appl. 8 - 10 Mac.*, no. April, pp. 8–10, 2016, doi: 10.1109/CSPA.2013.6530058.
- [35] M. M.-K. M. Kim, M. M.-K. M. Kim, E. Oh, and S.-P. Kim, “A Review on the Computational Methods for Emotional State Estimation from the Human EEG,” *Comput. Math. Methods Med.*, vol. 2013, pp. 1–13, 2013, doi: 10.1155/2013/573734.
- [36] G. Matthews, L. E. Reinerman-Jones, D. J. Barber, and J. Abich, “The psychometrics of mental workload: Multiple measures are sensitive but divergent,” *Hum. Factors*, vol. 57, no. 1, pp. 125–143, 2015, doi: 10.1177/0018720814539505.
- [37] Y. Yuan, G. Xun, K. Jia, and A. Zhang, “A multi-context learning approach for EEG epileptic seizure detection,” *BMC Syst. Biol.*, vol. 12, no. Suppl 6, 2018, doi: 10.1186/s12918-018-0626-2.
- [38] H. Sun, L. Bi, B. Chen, and Y. Guo, “EEG-based safety driving performance estimation and alertness using support vector machine,” *Int. J. Secur. Its Appl.*, vol. 9, no. 6, pp. 125–134, 2015, doi: 10.14257/ijisia.2015.9.6.13.
- [39] S. Puma, N. Matton, P.-V. V. Paubel, É. Raufaste, and R. El-Yagoubi, “Using theta and alpha band power to assess cognitive workload in multitasking environments,” *Int. J. Psychophysiol.*, vol. 123, no. November 2016, pp. 111–120, 2018, doi: 10.1016/j.ijpsycho.2017.10.004.
- [40] A. T. Kamzanova, A. M. Kustubayeva, and G. Matthews, “Use of EEG workload indices for diagnostic monitoring of vigilance decrement,” *Hum. Factors*, vol. 56, no. 6, pp. 1136–1149, 2014, doi: 10.1177/0018720814526617.
- [41] C. L. Baldwin and B. N. Penaranda, “Adaptive training using an artificial neural network and EEG metrics for within- and cross-task workload classification,” *Neuroimage*, vol. 59, no. 1, pp. 48–56, 2012, doi: 10.1016/j.neuroimage.2011.07.047.
- [42] R. Ramirez, Z. Vamvakousis, R. Ramirez, and Z. Vamvakousis, “Detecting Emotion from EEG Signals Using the Emotive Epoc Device Detecting Emotion from EEG Signals Using the Emotive Epoc Device,” *Int. Conf. Brain Informatics*, no. February, pp. 175–184, 2015, doi: 10.1007/978-3-642-35139-6.
- [43] E. Kabir, Siuly, and Y. Zhang, “Epileptic seizure detection from EEG signals using logistic model trees,” *Brain Informatics*, vol. 3, no. 2, pp. 93–100, 2016, doi: 10.1007/s40708-015-0030-2.
- [44] B. T. Jap, S. Lal, and P. Fischer, “Comparing combinations of EEG activity in train drivers during monotonous driving,” *Expert Syst. Appl.*, vol. 38, no. 1, pp. 996–1003, 2011, doi: 10.1016/j.eswa.2010.07.109.
- [45] H. Zhao, X. Guo, M. Wang, T. Li, C. Pang, and D. Georgakopoulos, “Analyze EEG signals with extreme learning machine based on PMIS feature selection,” *Int. J. Mach. Learn. Cybern.*, vol. 9, no. 2, pp. 243–249, 2018, doi: 10.1007/s13042-015-0378-x.
- [46] A. Kamzanova, A. Kustubayeva, and G. Matthews, “Diagnostic monitoring of vigilance decrement using EEG workload indices,” in *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, 2012, vol. 56, no. 1, pp. 203–207.
- [47] NeuroSky, “MindWave Mobile: User Guide.” [http://download.neurosky.com/support\\_page\\_files/MindWaveMobile/docs/mindwave\\_mobile\\_user\\_guide.pdf](http://download.neurosky.com/support_page_files/MindWaveMobile/docs/mindwave_mobile_user_guide.pdf) (accessed Jun. 11, 2021).



- [48] R. Kohavi and F. Provost, "Glossary of terms: Machine learning," *30 271*, vol. 274, 1998.
- [49] J. Grus, *Data science from scratch: first principles with python*. O'Reilly Media, 2019.
- [50] M. Stephen, *Chapman & Hall/CRC Machine Learning & Pattern Recognition Series Chapman & Hall/CRC Machine Learning & Pattern Recognition Series MACHINE LEARNING An Algorithmic Perspective*. 2014.
- [51] D. W. Patterson, *Artificial neural networks: theory and applications*. Prentice Hall PTR, 1998.
- [52] H. A. Kholerdi, N. TaheriNejad, R. Ghaderi, and Y. Baleghi, "Driver's drowsiness detection using an enhanced image processing technique inspired by the human visual system," *Conn. Sci.*, vol. 28, no. 1, pp. 27–46, 2016.
- [53] H. Cai, Z. Qu, Z. Li, Y. Zhang, X. Hu, and B. Hu, "Feature-level fusion approaches based on multimodal EEG data for depression recognition," *Inf. Fusion*, vol. 59, pp. 127–138, 2020.
- [54] K. Han, K. Song, and B. W. Choi, "How to develop, validate, and compare clinical prediction models involving radiological parameters: study design and statistical methods," *Korean J. Radiol.*, vol. 17, no. 3, pp. 339–350, 2016.
- [55] S. M. Weiss and N. Indurkha, *Predictive data mining: a practical guide*. Morgan Kaufmann, 1998.
- [56] F. Riaz, A. Hassan, S. Rehman, I. K. Niazi, and K. Dremstrup, "EMD-based temporal and spectral features for the classification of EEG signals using supervised learning," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 24, no. 1, pp. 28–35, 2015, doi: 10.1109/TNSRE.2015.2441835.
- [57] W. Wang, J. Xi, A. Chong, and L. Li, "Driving Style Classification Using a Semisupervised Support Vector Machine," *IEEE Trans. Human-Machine Syst.*, vol. 47, no. 5, pp. 650–660, 2017, doi: 10.1109/THMS.2017.2736948.
- [58] A. F., T. T.B., B. N., and T. B. O. <http://orcid.org/000-0002-5721-6828> Kiguchi M. AO - Tang, "Towards multilevel mental stress assessment using SVM with ECOC: an EEG approach," *Med. Biol. Eng. Comput.*, vol. 56, no. 1, pp. 125–136, 2018, doi: <http://dx.doi.org/10.1007/s11517-017-1733-8>.
- [59] A. Arasteh, M. H. Moradi, and A. Janghorbani, "A Novel Method Based on Empirical Mode Decomposition for P300-Based Detection of Deception," *IEEE Trans. Inf. Forensics Secur.*, vol. 11, no. 11, pp. 2584–2593, 2016, doi: 10.1109/TIFS.2016.2590938.
- [60] Z. Mohammadi, J. Frounchi, and M. Amiri, "Wavelet-based emotion recognition system using EEG signal," *Neural Comput. Appl.*, vol. 28, no. 8, pp. 1985–1990, 2017, doi: 10.1007/s00521-015-2149-8.
- [61] L. Wang *et al.*, "Automatic epileptic seizure detection in EEG signals using multi-domain feature extraction and nonlinear analysis," *Entropy*, vol. 19, no. 6, pp. 1–17, 2017, doi: 10.3390/e19060222.
- [62] S. Siuly, E. Kabir, H. Wang, and Y. Zhang, "Exploring sampling in the detection of multicategory EEG signals," *Comput. Math. Methods Med.*, vol. 2015, 2015, doi: 10.1155/2015/576437.
- [63] A. C. Lorena *et al.*, "Comparing machine learning classifiers in potential distribution modelling," *Expert Syst. Appl.*, vol. 38, no. 5, pp. 5268–5275, 2011.
- [64] M. Z. Baig, N. Aslam, and H. P. H. Shum, "Filtering techniques for channel selection in motor imagery EEG applications: a survey," *Artif. Intell. Rev.*, 2019, doi: 10.1007/s10462-019-09694-8.
- [65] M. Ma, X. Wanyan, and D. Zhuang, "Pilot Mental Workload Prediction Model based on Information Display Interface," doi: 10.1109/ICMTMA.2015.192.
- [66] Z. M. Wang, S. Y. Hu, and H. Song, "Channel Selection Method for EEG Emotion Recognition Using Normalized Mutual Information," *IEEE Access*, vol. 7, pp. 143303–143311, 2019, doi: 10.1109/ACCESS.2019.2944273.
- [67] A. Knoll *et al.*, "Measuring cognitive workload with low-cost electroencephalograph," in *IFIP Conference on Human-Computer Interaction*, 2011, pp. 568–571.
- [68] NASA TLX: Task Load Index, "NASA TLX." <https://humansystems.arc.nasa.gov/groups/tlx/> (accessed Jun. 11, 2021).
- [69] N. A. T. S. Air Traffic Management Development Centre, "Instantaneous Self Assessment of workload (ISA)." <https://skybrary.aero/bookshelf/books/1963.pdf> (accessed Jun. 11, 2021).
- [70] M. Murugappan and S. Murugappan, "Human emotion recognition through short time Electroencephalogram (EEG) signals using Fast Fourier Transform (FFT)," in *2013 IEEE 9th International Colloquium on Signal Processing and its Applications*, 2013, pp. 289–294.
- [71] Z. Liu, J. Sun, Y. Zhang, and P. Rolfe, "Sleep staging from the EEG signal using multi-domain feature extraction," *Biomed. Signal Process. Control*, vol. 30, pp. 86–97, 2016.
- [72] Chin-Teng Lin *et al.*, "Wireless and Wearable EEG System for Evaluating Driver Vigilance," *IEEE Trans. Biomed. Circuits Syst.*, vol. 8, no. 2, pp. 165–176, 2014, doi: 10.1109/TBCAS.2014.2316224.
- [73] W.-L. Zheng and B.-L. Lu, "Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks," *IEEE Trans. Auton. Ment. Dev.*, vol. 7, no. 3, pp. 162–175, 2015.
- [74] S. Jirayucharoensak, S. Pan-Ngum, and P. Israsena, "EEG-based emotion recognition using deep learning network with principal component based covariate shift adaptation," *Sci. World J.*, vol. 2014, 2014.
- [75] A. Martinez Rebollar, W. A. Sanchez Gomez, R. A. Benitez Garcia, Y. Gonzalez Baldizon, M. Mejia Lavalle, and J. Ortiz Hernandez, "A Job Stress Predictive Model Evaluation Through Classifier's

- Algorithms,” *IEEE Lat. Am. Trans.*, vol. 16, no. 1, pp. 178–185, 2018, doi: 10.1109/TLA.2018.8291471.
- [76] Emotiv Company, “Emotiv EPOC.” <https://www.emotiv.com/epoc/> (accessed Jun. 11, 2021).
- [77] G. Di Flumeri *et al.*, “EEG-based mental workload neurometric to evaluate the impact of different traffic and road conditions in real driving settings,” *Front. Hum. Neurosci.*, vol. 12, no. December, pp. 1–18, 2018, doi: 10.3389/fnhum.2018.00509.
- [78] O. R. Pinheiro, L. R. G. Alves, and J. R. de Souza, “EEG signals classification: Motor imagery for driving an intelligent wheelchair,” *IEEE Lat. Am. Trans.*, vol. 16, no. 1, pp. 254–259, 2018.
- [79] S. S. Daud and R. Sudirman, “Butterworth Bandpass and Stationary Wavelet Transform Filter Comparison for Electroencephalography Signal,” *Proc. - Int. Conf. Intell. Syst. Model. Simulation, ISMS*, vol. 2015-October, pp. 123–126, 2015, doi: 10.1109/ISMS.2015.29.
- [80] R. Yuvaraj *et al.*, “On the analysis of EEG power, frequency and asymmetry in Parkinson’s disease during emotion processing,” *Behav. brain Funct.*, vol. 10, no. 1, p. 12, 2014.
- [81] T. Thomas, M. James, R. R. Shaji, and B. C. Pillai, “Interpretation of human stages from EEG signals using LabVIEW,” *Int. J. Adv. Res. Comput. Commun. Eng.*, vol. 5, no. 3, 2016.
- [82] A. Reyes Rueda, “Interfaz cerebro computador mediante la clasificación de señales encefalográficas,” 2013.
- [83] N. N. Kulkarni and V. K. Bairagi, “Extracting Salient Features for EEG-based Diagnosis of Alzheimer’s Disease Using Support Vector Machine Classifier,” *IETE J. Res.*, vol. 63, no. 1, pp. 11–22, 2017, doi: 10.1080/03772063.2016.1241164.
- [84] E. P. Becerra Sanchez, A. Reyes Munoz, and J. A. Guerrero Ibanez, “Wearable Sensors for Evaluating Driver Drowsiness and High Stress,” *IEEE Lat. Am. Trans.*, vol. 17, no. 3, 2019, doi: 10.1109/TLA.2019.8863312.
- [85] X. Li, X. Chen, Y. Yan, W. Wei, and Z. J. Wang, “Classification of EEG signals using a multiple kernel learning support vector machine,” *Sensors*, vol. 14, no. 7, pp. 12784–12802, 2014, doi: 10.3390/s140712784.
- [86] W. Astuti, R. Akmeliawati, W. Sediono, and M.-J. E. Salami, “Hybrid technique using singular value decomposition (SVD) and support vector machine (SVM) approach for earthquake prediction,” *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, vol. 7, no. 5, pp. 1719–1728, 2014.
- [87] Y. Wang, B. Reimer, J. Dobres, and B. Mehler, “The sensitivity of different methodologies for characterizing drivers’ gaze concentration under increased cognitive demand,” *Transp. Res. part F traffic Psychol. Behav.*, vol. 26, pp. 227–237, 2014.
- [88] F. Pedregosa *et al.*, “Scikit-learn: Machine learning in Python,” *J. Mach. Learn. Res.*, vol. 12, pp. 2825–2830, 2011.
- [89] J.-B. Schiratti, J.-E. Le Douget, M. Le van Quyen, S. Essid, and A. Gramfort, “An ensemble learning approach to detect epileptic seizures from long intracranial EEG recordings,” in *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2018, pp. 856–860.
- [90] J. K. Johannesen, J. Bi, R. Jiang, J. G. Kenney, and C.-M. A. Chen, “Machine learning identification of EEG features predicting working memory performance in schizophrenia and healthy adults,” *Neuropsychiatr. Electrophysiol.*, vol. 2, no. 1, p. 3, 2016.
- [91] Y. Ma, X. Ding, Q. She, Z. Luo, T. Potter, and Y. Zhang, “Classification of motor imagery EEG signals with support vector machines and particle swarm optimization,” *Comput. Math. Methods Med.*, vol. 2016, 2016.
- [92] M. J. Khan and K.-S. Hong, “Passive BCI based on drowsiness detection: an fNIRS study,” *Biomed. Opt. Express*, vol. 6, no. 10, pp. 4063–4078, 2015.
- [93] J. Vicente, P. Laguna, A. Bartra, and R. Bailón, “Drowsiness detection using heart rate variability,” *Med. Biol. Eng. Comput.*, vol. 54, no. 6, pp. 927–937, 2016.
- [94] Y. Yang, H. Sun, T. Liu, G.-B. Huang, and O. Sourina, “Driver workload detection in on-road driving environment using machine learning,” in *Proceedings of ELM-2014 Volume 2*, Springer, 2015, pp. 389–398.
- [95] V. Faure, R. Lobjois, and N. Benguigui, “The effects of driving environment complexity and dual tasking on drivers’ mental workload and eye blink behavior,” *Transp. Res. part F traffic Psychol. Behav.*, vol. 40, pp. 78–90, 2016.
- [96] J. Liu, A. Gardi, S. Ramasamy, Y. Lim, and R. Sabatini, “Cognitive pilot-aircraft interface for single-pilot operations,” *Knowledge-Based Syst.*, vol. 112, pp. 37–53, 2016, doi: 10.1016/j.knosys.2016.08.031.
- [97] B. Nakisa, M. N. Rastgoo, D. Tjondronegoro, and V. Chandran, “Evolutionary computation algorithms for feature selection of EEG-based emotion recognition using mobile sensors,” *Expert Syst. Appl.*, vol. 93, pp. 143–155, 2018, doi: 10.1016/j.eswa.2017.09.062.
- [98] M. H. Bhatti *et al.*, “Soft Computing-Based EEG Classification by Optimal Feature Selection and Neural Networks,” *IEEE Trans. Ind. Informatics*, vol. 15, no. 10, pp. 5747–5754, 2019, doi: 10.1109/TII.2019.2925624.
- [99] W. Tao, C. Li, R. Song, J. Cheng, Y. Liu, and X. Chen, “EEG-based Emotion Recognition via Channel-

- wise Attention and Self Attention,” pp. 1–12.
- [100] Y. Liu *et al.*, “Multi-channel EEG-based emotion recognition via a multi-level features guided capsule network,” *Comput. Biol. Med.*, vol. 123, p. 103927, 2020.
- [101] V. Peterson, D. Wyser, O. Lambercy, R. Spies, and R. Gassert, “A penalized time-frequency band feature selection and classification procedure for improved motor intention decoding in multichannel EEG,” *J. Neural Eng.*, vol. 16, no. 1, p. 16019, 2019.
- [102] G. Tavares, R. San-Martin, J. N. Ianof, R. Anghinah, and F. J. Fraga, “Improvement in the automatic classification of Alzheimer’s disease using EEG after feature selection,” *Conf. Proc. - IEEE Int. Conf. Syst. Man Cybern.*, vol. 2019-October, pp. 1264–1269, 2019, doi: 10.1109/SMC.2019.8914006.
- [103] A. Arsalan, M. Majid, A. R. Butt, and S. M. Anwar, “Classification of Perceived Mental Stress Using A Commercially Available EEG Headband,” *IEEE J. Biomed. Heal. Informatics*, vol. 23, no. 6, pp. 2257–2264, 2019, doi: 10.1109/JBHI.2019.2926407.
- [104] J. Marín-Morales *et al.*, “Affective computing in virtual reality: emotion recognition from brain and heartbeat dynamics using wearable sensors,” *Sci. Rep.*, vol. 8, no. 1, pp. 1–15, 2018, doi: 10.1038/s41598-018-32063-4.
- [105] P. Batres-Mendoza *et al.*, “Quaternion-based signal analysis for motor imagery classification from electroencephalographic signals,” *Sensors (Switzerland)*, vol. 16, no. 3, 2016, doi: 10.3390/s16030336.
- [106] H. Sun, Y. Xiang, Y. Sun, H. Zhu, and J. Zeng, “On-line EEG classification for brain-computer interface based on CSP and SVM,” in *2010 3rd International Congress on Image and Signal Processing*, 2010, vol. 9, pp. 4105–4108.
- [107] S. Bhattacharyya, A. Khasnobish, S. Chatterjee, A. Konar, and D. N. Tibarewala, “Performance analysis of LDA, QDA and KNN algorithms in left-right limb movement classification from EEG data,” in *2010 International Conference on Systems in Medicine and Biology*, 2010, pp. 126–131.
- [108] Z. Guo, Y. Pan, G. Zhao, S. Cao, and J. Zhang, “Detection of Driver Vigilance Level Using EEG Signals and Driving Contexts,” *IEEE Trans. Reliab.*, vol. 67, no. 1, pp. 370–380, 2018, doi: 10.1109/TR.2017.2778754.
- [109] Y. Zhang *et al.*, “Multi-kernel extreme learning machine for EEG classification in brain-computer interfaces,” *Expert Syst. Appl.*, vol. 96, pp. 302–310, 2018, doi: 10.1016/j.eswa.2017.12.015.
- [110] D. R. Rahmad, Cahya and Ariyanto, Rudy and Yunianto, “Brain Signal Classification using Genetic Algorithm for Right-Left Motion Pattern,” *Int. J. Adv. Comput. Sci. Appl.*, vol. 9, no. 11, pp. 247–251, 2018.
- [111] P. P. Pal, Sankar K and Wang, “Genetic algorithms for pattern recognition,” *CRC Press*, 2017.
- [112] A. V. Phan, M. Le, N. Lam, T. Bui, M. Le Nguyen, and L. T. Bui, “Feature weighting and SVM parameters optimization based on genetic algorithms for classification problems,” *Appl. Intell.*, vol. 46, no. 2, pp. 455–469, 2017, doi: 10.1007/s10489-016-0843-6.
- [113] M. Asadur Rahman, M. Faisal Hossain, M. Hossain, and R. Ahmmed, “Employing PCA and t-statistical approach for feature extraction and classification of emotion from multichannel EEG signal,” *Egypt. Informatics J.*, vol. 21, no. 1, pp. 23–35, 2020, doi: 10.1016/j.eij.2019.10.002.
- [114] B. Thilakvathi, S. Shenbaga Devi, K. Bhanu, and M. Malaippan, “EEG signal complexity analysis for schizophrenia during rest and mental activity,” *Biomed. Res.*, vol. 28, no. 1, pp. 1–9, 2017.
- [115] R. Jenke, A. Peer, and M. Buss, “Feature extraction and selection for emotion recognition from EEG,” *IEEE Trans. Affect. Comput.*, vol. 5, no. 3, pp. 327–339, Jul. 2014, doi: 10.1109/TAFFC.2014.2339834.
- [116] S. Koelstra *et al.*, “DEAP: A database for emotion analysis; Using physiological signals,” *IEEE Trans. Affect. Comput.*, vol. 3, no. 1, pp. 18–31, 2012, doi: 10.1109/T-AFFC.2011.15.
- [117] J. K. Nuamah and Y. Seong, “Neural correspondence to human cognition from analysis to intuition-implications of display design for cognition,” *Proc. Hum. Factors Ergon. Soc.*, vol. 2017-October, no. 2001, pp. 51–55, 2017, doi: 10.1177/1541931213601508.
- [118] G. Di Flumeri, P. Aricò, G. Borghini, N. Sciaraffa, A. Di Florio, and F. Babiloni, “The dry revolution: Evaluation of three different eeg dry electrode types in terms of signal spectral features, mental states classification and usability,” *Sensors (Switzerland)*, vol. 19, no. 6, pp. 1–21, 2019, doi: 10.3390/s19061365.
- [119] X.-Q. Huo, W.-L. Zheng, and B.-L. Lu, “Driving fatigue detection with fusion of EEG and forehead EOG,” in *2016 international joint conference on neural networks (IJCNN)*, 2016, pp. 897–904.
- [120] Nils A. Reinke, “What Is the Difference between?,” *Western Folklore*, 2020. [https://www.linkedin.com/pulse/accuracy-precision-nils-reinke?trk=related\\_article\\_What is the difference between Accuracy %26amp%3Bamp%3Bamp%3B Precision%3F\\_article-card\\_title](https://www.linkedin.com/pulse/accuracy-precision-nils-reinke?trk=related_article_What%20is%20the%20difference%20between%20Accuracy%20%26amp%3Bamp%3Bamp%3B%20Precision%3F_article-card_title) (accessed Jun. 11, 2021).
- [121] D. E. Golberg, “Genetic algorithms in search, optimization, and machine learning,” *Addion wesley*, vol. 1989, no. 102, p. 36, 1989.
- [122] I. Beheshti, H. Demirel, and H. Matsuda, “Classification of Alzheimer’s disease and prediction of mild cognitive impairment-to-Alzheimer’s conversion from structural magnetic resource imaging using feature ranking and a genetic algorithm,” *Comput. Biol. Med.*, vol. 83, no. November 2016, pp. 109–119, 2017, doi: 10.1016/j.combiomed.2017.02.011.



- [123] A. Hassanat, K. Almohammadi, E. Alkafaween, E. Abunawas, A. Hammouri, and V. B. S. Prasath, "Choosing mutation and crossover ratios for genetic algorithms-a review with a new dynamic approach," *Inf.*, vol. 10, no. 12, 2019, doi: 10.3390/info10120390.
- [124] F.-A. Fortin, F.-M. De Rainville, M.-A. G. Gardner, M. Parizeau, and C. Gagné, "DEAP: Evolutionary algorithms made easy," *J. Mach. Learn. Res.*, vol. 13, no. 1, pp. 2171–2175, 2012.
- [125] F.-M. De Rainville, F.-A. Fortin, M.-A. Gardner, M. Parizeau, and C. Gagné, "DEAP: enabling nimbler evolutions," *ACM SIGEVolution*, vol. 6, no. 2, pp. 17–26, 2014.
- [126] C. Tantithamthavorn, S. McIntosh, A. E. Hassan, and K. Matsumoto, "An Empirical Comparison of Model Validation Techniques for Defect Prediction Models," *IEEE Trans. Softw. Eng.*, vol. 43, no. 1, pp. 1–18, 2017, doi: 10.1109/TSE.2016.2584050.
- [127] S. K. Satapathy, S. Dehuri, and A. K. Jagadev, "EEG signal classification using PSO trained RBF neural network for epilepsy identification," *Informatics Med. Unlocked*, vol. 6, no. June 2016, pp. 1–11, 2017, doi: 10.1016/j.imu.2016.12.001.
- [128] B-Alert, "Cognitive-affective metrics," 2020. <https://imotions.com/blog/eeg/> (accessed Jun. 11, 2021).
- [129] A. Eldenfria and H. Al-Samarraie, "Towards an Online Continuous Adaptation Mechanism (OCAM) for Enhanced Engagement: An EEG Study," *Int. J. Hum. Comput. Interact.*, vol. 35, no. 20, pp. 1960–1974, 2019, doi: 10.1080/10447318.2019.1595303.
- [130] R. Ramirez, M. Palencia-Lefler, S. Giraldo, and Z. Vamvakousis, "Musical neurofeedback for treating depression in elderly people," *Front. Neurosci.*, vol. 9, p. 354, 2015.
- [131] G. Fison et al., "Combining EEG signal processing with supervised methods for Alzheimer's patients classification," *BMC Med. Inform. Decis. Mak.*, vol. 18, no. 1, pp. 1–10, 2018.
- [132] J. K. Nuamah and Y. Seong, "Support vector machine (SVM) classification of cognitive tasks based on electroencephalography (EEG) engagement index," *Brain-Computer Interfaces*, vol. 5, no. 1, pp. 1–12, 2018, doi: 10.1080/2326263X.2017.1338012.
- [133] P. C. Petrantonakis and J. Leontios, "EEG-based emotion recognition using advanced signal processing techniques," *Emot. Recognit. A Pattern Anal. Approach*, pp. 269–293, 2014.
- [134] MILIND GAIKWAD, "Effect of Meditation on Cognitive Workload," in *EEG-Based Emotion Analysis and Recognition*, Nanded Maharashtra India, 2019, pp. 88–107.
- [135] P. Philip et al., "Fatigue, sleepiness, and performance in simulated versus real driving conditions," *Sleep*, vol. 28, no. 12, pp. 1511–1516, 2005, doi: 10.1093/sleep/28.12.1511.
- [136] Z. C. Zacharia, "Comparing and combining real and virtual experimentation: An effort to enhance students' conceptual understanding of electric circuits," *J. Comput. Assist. Learn.*, vol. 23, no. 2, pp. 120–132, 2007, doi: 10.1111/j.1365-2729.2006.00215.x.
- [137] J. Micallef et al., "Cannabis smoking impairs driving performance on the simulator and real driving: a randomized, double-blind, placebo-controlled, crossover trial," *Fundam. Clin. Pharmacol.*, vol. 32, no. 5, pp. 558–570, 2018.
- [138] M. Krause, "LCT FOR SILAB." <https://www.mw.tum.de/en/lfc/downloads/open-source-tools/lct-for-silab/> (accessed Jun. 11, 2021).
- [139] S. Mattes and A. Hallén, "Surrogate distraction measurement techniques: The lane change test," *Driv. distraction Theory, Eff. Mitig.*, pp. 107–121, 2009.
- [140] J. Engström and G. Markkula, "Effects of visual and cognitive distraction on lane change test performance," 2007.
- [141] K. L. Young, M. G. Lenné, and A. R. Williamson, "Sensitivity of the lane change test as a measure of in-vehicle system demand," *Appl. Ergon.*, vol. 42, no. 4, pp. 611–618, 2011, doi: 10.1016/j.apergo.2010.06.020.
- [142] S. Mattes, "The Lane Change Task as a tool for driver distraction evaluation," *Qual. Work Prod. Enterp. Futur.*, vol. 57, no. January 2003, p. 60, 2003.
- [143] A. J. TATTERSALL and P. S. FOORD, "An experimental evaluation of instantaneous self-assessment as a measure of workload," *Ergonomics*, vol. 39, no. 5, pp. 740–748, May 1996, doi: 10.1080/00140139608964495.
- [144] K. Yu, I. Prasad, H. Mir, N. Thakor, and H. Al-Nashash, "Cognitive workload modulation through degraded visual stimuli: A single-trial EEG study," *J. Neural Eng.*, vol. 12, no. 4, 2015, doi: 10.1088/1741-2560/12/4/046020.
- [145] E. Parvinnia, M. Sabeti, M. Z. Jahromi, and R. Boostani, "Classification of EEG Signals using adaptive weighted distance nearest neighbor algorithm," *J. King Saud Univ. Inf. Sci.*, vol. 26, no. 1, pp. 1–6, 2014.
- [146] A. Zammouri et al., "Brain waves-based index for workload estimation and mental effort engagement recognition," *J. Phys. Conf. Ser.*, vol. 904, no. 1, 2017, doi: 10.1088/1742-6596/904/1/012008.
- [147] J. K. Nuamah, Y. Seong, and S. Yi, "Electroencephalography (EEG) classification of cognitive tasks based on task engagement index," in *2017 IEEE Conference on Cognitive and Computational Aspects of Situation Management (CogSIMA)*, 2017, pp. 1–6.
- [148] Q. Lin, J. B. Huang, J. Zhong, S. Da Lin, and Y. Xue, "Feature selection and recognition of

- electroencephalogram signals: An extreme learning machine and genetic algorithm-based approach,” *Proc. - Int. Conf. Mach. Learn. Cybern.*, vol. 2, pp. 499–504, 2015, doi: 10.1109/ICMLC.2015.7340607.
- [149] P. Tao, Z. Sun, and Z. Sun, “An Improved Intrusion Detection Algorithm Based on GA and SVM,” *IEEE Access*, vol. 6, pp. 13624–13631, 2018, doi: 10.1109/ACCESS.2018.2810198.
- [150] P. Johnson *et al.*, “Genetic algorithm with logistic regression for prediction of progression to Alzheimer’s disease,” *BMC Bioinformatics*, vol. 15, no. Suppl 16, pp. 1–14, 2014, doi: 10.1186/1471-2105-15-S16-S11.
- [151] C. Amo, L. de Santiago, R. Barea, A. López-Dorado, and L. Boquete, “Analysis of gamma-band activity from human EEG using empirical mode decomposition,” *Sensors (Switzerland)*, vol. 17, no. 5, 2017, doi: 10.3390/s17050989.
- [152] I. Käthner, S. C. Wriessnegger, G. R. Müller-Putz, A. Kübler, and S. Halder, “Effects of mental workload and fatigue on the P300, alpha and theta band power during operation of an ERP (P300) brain–computer interface,” *Biol. Psychol.*, vol. 102, pp. 118–129, 2014.
- [153] G. Borghini, L. Astolfi, G. Vecchiato, D. Mattia, and F. Babiloni, “Measuring neurophysiological signals in aircraft pilots and car drivers for the assessment of mental workload, fatigue and drowsiness,” *Neurosci. Biobehav. Rev.*, vol. 44, pp. 58–75, 2014, doi: 10.1016/j.neubiorev.2012.10.003.
- [154] W. L. Zheng and B. L. Lu, “A multimodal approach to estimating vigilance using EEG and forehead EOG,” *J. Neural Eng.*, vol. 14, no. 2, 2017, doi: 10.1088/1741-2552/aa5a98.
- [155] M. Mahmoudi and M. Shamsi, “Multi-class EEG classification of motor imagery signal by finding optimal time segments and features using SNR-based mutual information,” *Australas. Phys. Eng. Sci. Med.*, vol. 41, no. 4, pp. 957–972, 2018.
- [156] Y. Tian, W. Xu, and L. Yang, “Cortical Classification with Rhythm Entropy for Error Processing in Cocktail Party Environment Based on Scalp EEG Recording,” *Sci. Rep.*, vol. 8, no. 1, pp. 1–13, 2018, doi: 10.1038/s41598-018-24535-4.
- [157] W.-L. Zheng, J.-Y. Zhu, and B.-L. Lu, “Identifying Stable Patterns over Time for Emotion Recognition from EEG,” *IEEE Trans. Affect. Comput.*, vol. 10, no. 3, pp. 417–429, 2017, doi: 10.1109/taffc.2017.2712143.
- [158] V. Bajaj, S. Taran, and A. Sengur, “Emotion classification using flexible analytic wavelet transform for electroencephalogram signals,” *Heal. Inf. Sci. Syst.*, vol. 6, no. 1, pp. 1–7, 2018, doi: 10.1007/s13755-018-0048-y.
- [159] D. Shon, K. Im, J. H. Park, D. S. Lim, B. Jang, and J. M. Kim, “Emotional stress state detection using genetic algorithm-based feature selection on EEG signals,” *Int. J. Environ. Res. Public Health*, vol. 15, no. 11, 2018, doi: 10.3390/ijerph15112461.
- [160] O. Valenzuela, X. Jiang, A. Carrillo, and I. Rojas, “Multi-Objective Genetic Algorithms to Find Most Relevant Volumes of the Brain Related to Alzheimer’s Disease and Mild Cognitive Impairment,” *Int. J. Neural Syst.*, vol. 28, no. 9, 2018, doi: 10.1142/S0129065718500223.
- [161] N. S. Malan and S. Sharma, “Feature selection using regularized neighbourhood component analysis to enhance the classification performance of motor imagery signals,” *Comput. Biol. Med.*, vol. 107, no. February, pp. 118–126, 2019, doi: 10.1016/j.compbiomed.2019.02.009.
- [162] M. Leon, J. Ballesteros, J. Tidare, N. Xiong, and E. Astrand, “Feature Selection of EEG Oscillatory Activity Related to Motor Imagery Using a Hierarchical Genetic Algorithm,” *2019 IEEE Congr. Evol. Comput. CEC 2019 - Proc.*, pp. 87–94, 2019, doi: 10.1109/CEC.2019.8789948.
- [163] C. A. Ramezan, T. A. Warner, and A. E. Maxwell, “Evaluation of sampling and cross-validation tuning strategies for regional-scale machine learning classification,” *Remote Sens.*, vol. 11, no. 2, 2019, doi: 10.3390/rs11020185.
- [164] P. Tan, X. Wang, and Y. Wang, “Dimensionality reduction in evolutionary algorithms-based feature selection for motor imagery brain-computer interface,” *Swarm Evol. Comput.*, vol. 52, no. November 2019, p. 100597, 2020, doi: 10.1016/j.swevo.2019.100597.
- [165] Z. Tao, L. Huiling, W. Wenwen, and Y. Xia, “GA-SVM based feature selection and parameter optimization in hospitalization expense modeling,” *Appl. Soft Comput.*, vol. 75, pp. 323–332, 2019.
- [166] C. Sukawattanavijit, J. Chen, and H. Zhang, “GA-SVM algorithm for improving land-cover classification using SAR and optical remote sensing data,” *IEEE Geosci. Remote Sens. Lett.*, vol. 14, no. 3, pp. 284–288, 2017.
- [167] W.-L. Zheng and B.-L. Lu, “A multimodal approach to estimating vigilance using {EEG} and forehead {EOG},” *J. Neural Eng.*, vol. 14, no. 2, p. 26017, Feb. 2017, doi: 10.1088/1741-2552/aa5a98.
- [168] S. Abu, I. Alfarozzi, and N. A. Setiawan, “Analytical Incremental Learning : Fast Constructive Learning Method,” vol. 2, no. October 2016, pp. 259–268, 2016, doi: 10.1007/978-3-319-46672-9.
- [169] X. Li, D. Song, P. Zhang, Y. Zhang, Y. Hou, and B. Hu, “Exploring EEG features in cross-subject emotion recognition,” *Front. Neurosci.*, vol. 12, no. MAR, 2018, doi: 10.3389/fnins.2018.00162.
- [170] V. Gupta, M. D. Chopda, and R. B. Pachori, “Cross-Subject Emotion Recognition Using Flexible Analytic Wavelet Transform from EEG Signals,” *IEEE Sens. J.*, vol. 19, no. 6, pp. 2266–2274, 2019, doi: 10.1109/JSEN.2018.2883497.

- [171] S. Hwang, K. Hong, G. Son, and H. Byun, "Learning CNN features from DE features for EEG-based emotion recognition," *Pattern Anal. Appl.*, vol. 23, no. 3, pp. 1323–1335, 2019, doi: 10.1007/s10044-019-00860-w.
- [172] P. Li *et al.*, "EEG Based Emotion Recognition by Combining Functional Connectivity Network and Local Activations," *IEEE Trans. Biomed. Eng.*, vol. 66, no. 10, pp. 2869–2881, 2019, doi: 10.1109/TBME.2019.2897651.
- [173] C. Fadil, R. Alvarez, C. Martínez, J. Goddard, and H. Rufiner, "Multimodal emotion recognition using deep networks," *IFMBE Proc.*, vol. 49, pp. 813–816, 2015, doi: 10.1007/978-3-319-13117-7\_207.
- [174] Y. Yang, Q. M. J. Wu, W. L. Zheng, and B. L. Lu, "EEG-based emotion recognition using hierarchical network with subnetwork nodes," *IEEE Trans. Cogn. Dev. Syst.*, vol. 10, no. 2, pp. 408–419, 2018, doi: 10.1109/TCDS.2017.2685338.
- [175] W. Zheng, "Multichannel EEG-Based Emotion Recognition via Group Sparse Canonical Correlation Analysis," *IEEE Trans. Cogn. Dev. Syst.*, vol. 9, no. 3, pp. 281–290, 2017, doi: 10.1109/TCDS.2016.2587290.
- [176] S. Thejaswini, K. M. Ravi Kumar, S. Rupali, and V. Abijith, "EEG based emotion recognition using wavelets and neural networks classifier," *SpringerBriefs Appl. Sci. Technol.*, no. 9789811066979, pp. 101–112, 2018, doi: 10.1007/978-981-10-6698-6\_10.
- [177] J. H. Holland, *Adaptation in natural and artificial systems: an introductory analysis with applications to biology, control, and artificial intelligence*. MIT press, 1992.
- [178] B. Nakisa, M. Z. A. Nazri, M. N. Rastgoo, and S. Abdullah, "A SURVEY: PARTICLE SWARM OPTIMIZATION BASED ALGORITHMS TO SOLVE PREMATURE CONVERGENCE PROBLEM," *J. Comput. Sci.*, vol. 10, no. 9 SE-Research Article, Apr. 2014, doi: 10.3844/jcssp.2014.1758.1765.
- [179] G. Pavai and T. V. Geetha, "New crossover operators using dominance and co-dominance principles for faster convergence of genetic algorithms," *Soft Comput.*, vol. 23, no. 11, pp. 3661–3686, 2019.
- [180] M. Muja and D. G. Lowe, "Scalable nearest neighbor algorithms for high dimensional data," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 36, no. 11, pp. 2227–2240, 2014, doi: 10.1109/TPAMI.2014.2321376.
- [181] Y. Liu and O. Sourina, "EEG databases for emotion recognition," in *2013 international conference on cyberworlds*, 2013, pp. 302–309.
- [182] P. Gupta, A. Sharma, and R. Jindal, "Scalable machine-learning algorithms for big data analytics: a comprehensive review," *Wiley Interdiscip. Rev. Data Min. Knowl. Discov.*, vol. 6, no. 6, pp. 194–214, 2016, doi: 10.1002/widm.1194.
- [183] X. Li, L. Gao, W. Wang, C. Wang, and L. Wen, "Particle swarm optimization hybridized with genetic algorithm for uncertain integrated process planning and scheduling with interval processing time," *Comput. Ind. Eng.*, vol. 135, no. April, pp. 1036–1046, 2019, doi: 10.1016/j.cie.2019.04.028.
- [184] L. R. Abreu, J. O. Cunha, B. A. Prata, and J. M. Framinan, "A genetic algorithm for scheduling open shops with sequence-dependent setup times," *Comput. Oper. Res.*, vol. 113, p. 104793, 2020, doi: 10.1016/j.cor.2019.104793.
- [185] B. J. Marafino *et al.*, "Validation of Prediction Models for Critical Care Outcomes Using Natural Language Processing of Electronic Health Record Data," *JAMA Netw. open*, vol. 1, no. 8, p. e185097, 2018, doi: 10.1001/jamanetworkopen.2018.5097.
- [186] J. A. Russell, "A circumplex model of affect," *J. Pers. Soc. Psychol.*, vol. 39, no. 6, p. 1161, 1980.
- [187] D. Abad-Tortosa, R. Costa, A. Alacreu-Crespo, V. Hidalgo, A. Salvador, and M. Á. Serrano, "Hormonal and emotional responses to competition using a dyadic approach: Basal testosterone predicts emotional state after a defeat," *Physiol. Behav.*, vol. 206, pp. 106–117, 2019.
- [188] M. Bartosova, M. Svetlak, M. Kukletova, P. B. Linhartova, L. Dusek, and L. I. Holla, "Emotional stimuli candidates for behavioural intervention in the prevention of early childhood caries: a pilot study," *BMC Oral Health*, vol. 19, no. 1, p. 33, 2019.
- [189] N. Kumar, K. Khaund, and S. M. Hazarika, "Bispectral Analysis of EEG for Emotion Recognition," *Procedia Comput. Sci.*, vol. 84, pp. 31–35, 2016, doi: 10.1016/j.procs.2016.04.062.
- [190] H. Ullah, M. Uzair, A. Mahmood, M. Ullah, S. D. Khan, and F. A. Cheikh, "Internal Emotion Classification Using EEG Signal with Sparse Discriminative Ensemble," *IEEE Access*, vol. 7, pp. 40144–40153, 2019, doi: 10.1109/ACCESS.2019.2904400.
- [191] C. Mühl, B. Allison, A. Nijholt, and G. Chanel, "A survey of affective brain computer interfaces: principles, state-of-the-art, and challenges," *Brain-Computer Interfaces*, vol. 1, no. 2, pp. 66–84, 2014.
- [192] A. Al-Nafjan, M. Hosny, A. Al-Wabil, and Y. Al-Ohali, "Classification of Human Emotions from Electroencephalogram (EEG) Signal using Deep Neural Network," *Int. J. Adv. Comput. Sci. Appl.*, vol. 8, no. 9, pp. 419–425, 2017, doi: 10.14569/ijacsa.2017.080955.
- [193] A. Mert and A. Akan, "Emotion recognition from EEG signals by using multivariate empirical mode decomposition," *Pattern Anal. Appl.*, vol. 21, no. 1, pp. 81–89, 2018, doi: 10.1007/s10044-016-0567-6.
- [194] I. Wichakam and P. Vateekul, "An evaluation of feature extraction in EEG-based emotion prediction

- with support vector machines,” *2014 11th Int. Jt. Conf. Comput. Sci. Softw. Eng. "Human Factors Comput. Sci. Softw. Eng. - e-Science High Perform. Comput. eHPC, JCSSE 2014*, pp. 106–110, 2014, doi: 10.1109/JCSSE.2014.6841851.
- [195] M. L. R. Menezes *et al.*, “Towards emotion recognition for virtual environments: an evaluation of eeg features on benchmark dataset,” *Pers. Ubiquitous Comput.*, vol. 21, no. 6, pp. 1003–1013, 2017, doi: 10.1007/s00779-017-1072-7.
- [196] S. Siddharth, T.-P. Jung, and T. J. Sejnowski, “Utilizing Deep Learning Towards Multi-modal Bio-sensing and Vision-based Affective Computing,” *IEEE Trans. Affect. Comput.*, pp. 1–1, 2019, doi: 10.1109/taffc.2019.2916015.
- [197] S. Tripathi, S. Acharya, R. D. Sharma, S. Mittal, and S. Bhattacharya, “Using Deep and Convolutional Neural Networks for Accurate Emotion Classification on DEAP Dataset,” 2017.
- [198] S. Y. Chung and H. J. Yoon, “Affective classification using Bayesian classifier and supervised learning,” in *2012 12th International Conference on Control, Automation and Systems*, 2012, pp. 1768–1771.
- [199] J. Atkinson and D. Campos, “Improving BCI-based emotion recognition by combining EEG feature selection and kernel classifiers,” *Expert Syst. Appl.*, vol. 47, pp. 35–41, 2016, doi: 10.1016/j.eswa.2015.10.049.
- [200] H. Candra, M. Yuwono, A. Handojoseno, R. Chai, S. Su, and H. T. Nguyen, “Recognizing emotions from EEG subbands using wavelet analysis,” in *2015 37th annual international conference of the IEEE engineering in medicine and biology society (EMBC)*, 2015, pp. 6030–6033.
- [201] F. Feradov and T. Ganchev, “Detection of negative emotional states from electroencephalographic (EEG) signals,” *Annu. J. Electron.*, vol. 8, pp. 66–69, 2014.
- [202] K. Guo, H. Candra, H. Yu, H. Li, H. T. Nguyen, and S. W. Su, “EEG-based emotion classification using innovative features and combined SVM and HMM classifier,” *Proc. Annu. Int. Conf. IEEE Eng. Med. Biol. Soc. EMBS*, pp. 489–492, 2017, doi: 10.1109/EMBC.2017.8036868.
- [203] M. Soleymani, F. Villaro-Dixon, T. Pun, and G. Chanel, “Toolbox for Emotional feAture extraction from Physiological signals (TEAP),” *Front. ICT*, vol. 4, no. FEB, pp. 1–7, 2017, doi: 10.3389/fict.2017.00001.
- [204] C. Series, “Emotion Recognition Based on DEAP Database using EEG Time- Frequency Features and Machine Learning Methods Emotion Recognition Based on DEAP Database using EEG Time-Frequency Features and Machine Learning Methods,” 2020, doi: 10.1088/1742-6596/1501/1/012020.
- [205] P. Da Pelo, M. De Tommaso, A. Monaco, S. Stramaglia, R. Bellotti, and S. Tangaro, “Trial latencies estimation of event-related potentials in EEG by means of genetic algorithms,” *J. Neural Eng.*, vol. 15, no. 2, 2018, doi: 10.1088/1741-2552/aa9b97.
- [206] M. Diykh and Y. Li, “Complex networks approach for EEG signal sleep stages classification,” *Expert Syst. Appl.*, vol. 63, pp. 241–248, 2016.
- [207] E. C. Djamal and P. Lodaya, “Eeg based emotion monitoring using wavelet and learning vector quantization,” *Int. Conf. Electr. Eng. Comput. Sci. Informatics*, vol. 4, no. September, pp. 98–103, 2017, doi: 10.11591/eecs.4.1053.
- [208] B. E. Bilgin and V. C. Gungor, “Performance comparison of ieee 802.11p and IEEE 802.11b for vehicle-to-vehicle communications in highway, rural, and urban areas,” *Int. J. Veh. Technol.*, vol. 2013, 2013, doi: 10.1155/2013/971684.
- [209] Emotiv inc, “Emotiv Software Development Kit User Manual,” 2015. [http://www.cmap.polytechnique.fr/~jingrebecali/ecole\\_dete\\_france\\_excellence\\_files\\_2017/UserManualForEmotivXavierControlPanel\\_Epoc.pdf](http://www.cmap.polytechnique.fr/~jingrebecali/ecole_dete_france_excellence_files_2017/UserManualForEmotivXavierControlPanel_Epoc.pdf) (accessed Jun. 11, 2021).
- [210] NI Community, “Emotiv Example for Reading EEG Commands,” 2011. <https://forums.ni.com/t5/Example-Code/Emotiv-Example-for-Reading-EEG-Commands/ta-p/3503423?profile.language=en> (accessed Jun. 11, 2021).
- [211] “LabVIEW Emotiv Toolkit V2,” 2014. <https://forums.ni.com/t5/Example-Code/LabVIEW-Emotiv-Toolkit-V2/ta-p/3493301?profile.language=en> (accessed Jun. 11, 2021).
- [212] J. Ortega Rodríguez, “Puesta a punto de sistema de electroencefalografía portátil,” 2015.



## Anexo A: Adquisición de las Señales EEG Utilizando el sensor Emotiv y la Herramienta LabView

La adquisición de la señal EEG se realiza utilizando el sensor Emotiv EPOC headset. Este dispositivo envía los datos de forma inalámbrica a un receptor USB y cuenta con un software SDK que controla varios aspectos como si los electrodos del sensor hacen contacto con la piel, el tiempo de conexión, la intensidad de la señal inalámbrica, el nivel de la batería del dispositivo y los usuarios como se muestra en la Figura 45 [209].

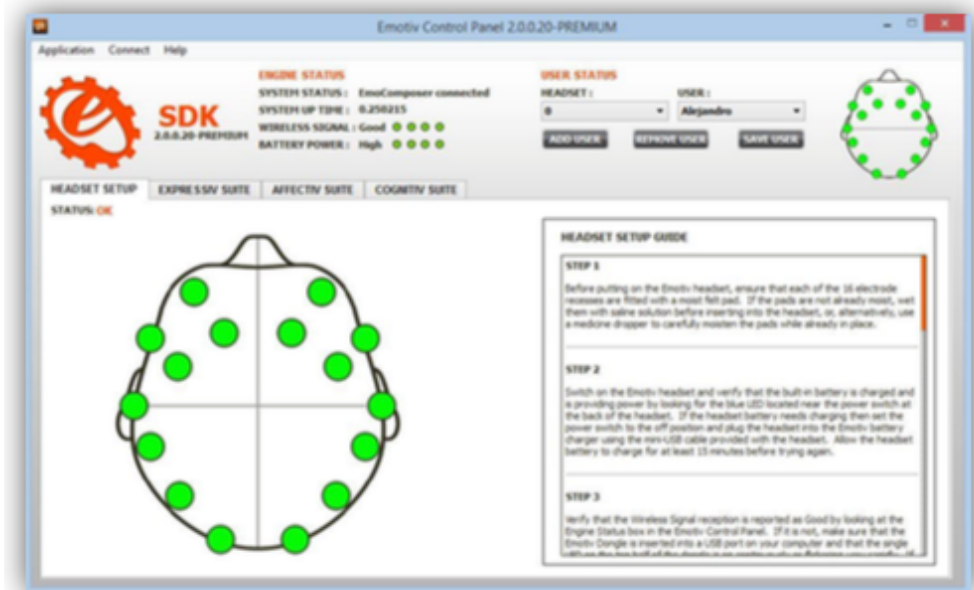


Figura 45 Panel de control del sensor Emotiv EPOC

El sensor debe ser colocado en la cabeza del sujeto deslizándose suavemente hacia abajo como de observa en Figura 46 (a). Es importante que los sensores de referencia (gyros) quedan ubicados justo detrás de cada lóbulo de la oreja y que los electrodos frontales (AF4 y AF5) se encuentren ubicados a 3 dedos por encima de la ceja como se ve en la Figura 46 (b) y (c) ya que la correcta captura de los datos dependerá principalmente del posicionamiento de estos sensores.

Para realizar la captura de la señal EEG en tiempo real, se desarrolló un programa de tipo Testbench utilizando la herramienta de LabVIEW Instrument, VI package manager y la librería Emotiv Toolkit. El programa desarrollado basado en [79][34][210][211], utiliza el archivo edk.dll que genera el sensor para visualizar la señal EEG y almacenarlas en un archivo con extensión \*.vvs. La interfaz separa los datos adquiridos de los 14 electrodos por canal, habilitado o deshabilitado solo los canales de interés para su visualización y almacenamiento. A continuación, en la Figura 47 se presenta el panel de control desarrollado.




Figura 46 Colocación del sensor Emotiv EPOC

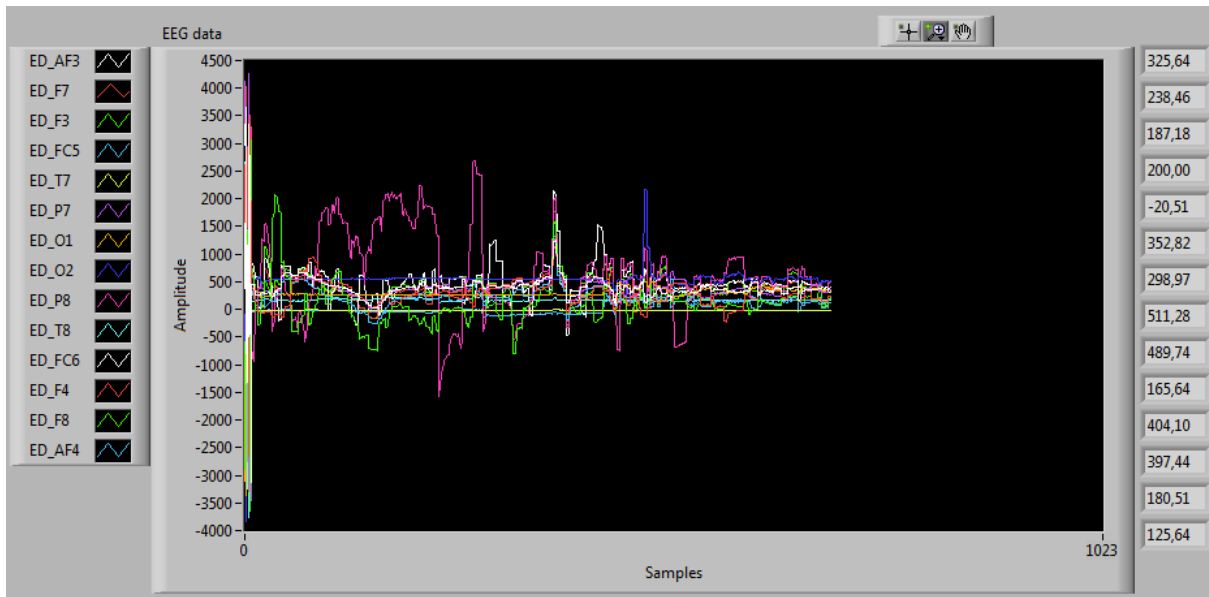


Figura 47 Panel de control para la visualización y almacenamiento de las señales EEG

En la Figura 48 se presenta el diagrama de bloques desarrollado para capturar y almacenar las señales de cada canal en tiempo real [212]. Las funciones vi utilizadas para realiza la conexión entre el sensor y el ordenador son las siguientes:

- EmotivCreate Task.vi: carga el archivo edk.dll.
- EmotivStart Task.vi: permite visualizar el contenido del archivo edk.dll identificando los datos de las señales EEG
- EEG Data.vi: adquiere las señales EEG que provienen de cada electrodo. Se define un número de muestras de datos disponibles para crear un búfer de datos de ingreso.
- Set Marker.vi: permite marcar eventos durante la adquisición de las señales EEG.

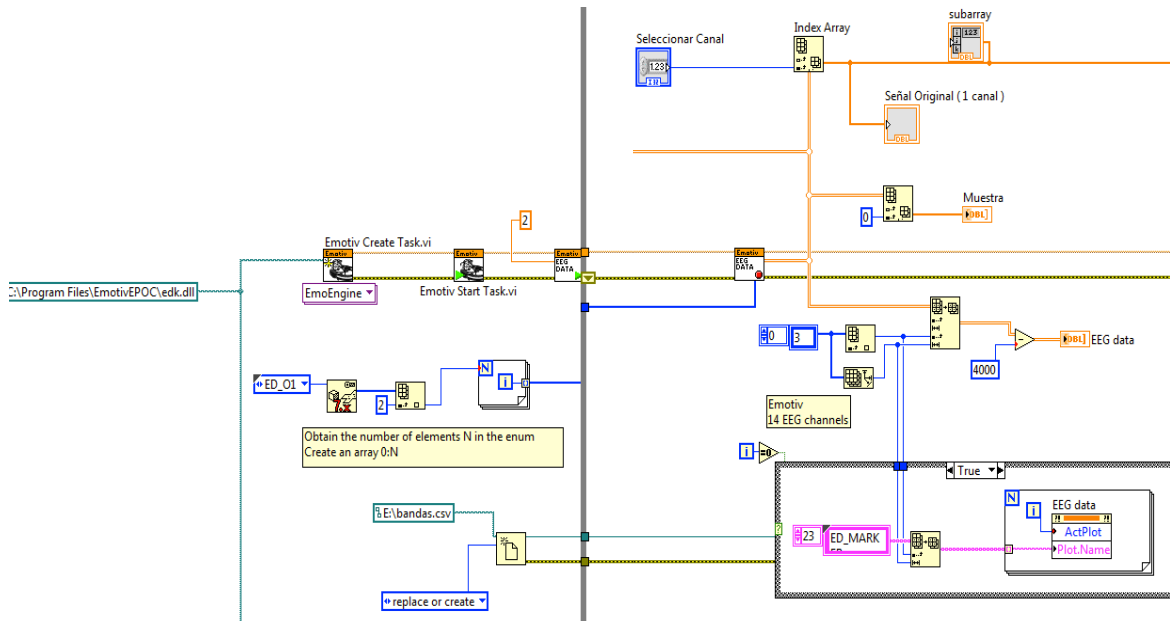


Figura 48 Diagrama de bloques de la visualización de las señales EEG

La información recolectada por la interfaz desarrollada es almacenada en un archivo con extensión \*.csv como se observan en la Figura 49. A continuación, se presenta la información que genera el sensor durante la recolección de los datos [212].

1. COUNTER: contador de los paquetes de datos recibidos, este va desde 0 hasta 128 debido a que la frecuencia de muestreo realizado por el headset de Emotiv es de 128Hz.
2. ED\_INTERPOLATED: indica la cantidad de paquetes perdidos.
3. ED\_RAW\_CQ: medida de conductividad multiplexada para indicar el nivel de la calidad de conexión en la aplicación. Es posible multiplexar este canal si se requieren mediciones de conductividad más precisas. El multiplexor realiza dos ciclos de 129 muestras por electrodo.
4. Canales AF3 F7 F3 FC5 T7 P7 O1 O2 P8 T8 FC6 F4 F8 AF4: Información de cada canal en microvoltios (uV).
5. ED\_GYROX: información horizontal y vertical de los sensores de referencia.
6. ED\_TIMESTAMP: tiempo dado en segundos entre cada una de las muestras
7. ED\_MARKER: valor de los marcadores insertado. Si no se detecta un marcador en la muestra, se agrega un valor de 0.

Development of cognitive workload models to detect driving impairment

TimeStamp	ED_COUNT	ED_INTERPO	ED_RAW	CC_ED_AF3	ED_F7	ED_F3	ED_F5	ED_T7	ED_P7	ED_O1	ED_P8	ED_T8	ED_F6	ED_F4	ED_F8	ED_AF7	ED_GV0X	ED_GV0Y	ED_TIMERATED	ES_TIME	ED_FUNC	ICED_FUNC	V_ED_MARKER	ED :	
19:02:32	114	0	0	0	4151.79487	4238.21795	4172.30769	4136.41026	3793.33333	3885.12621	3948.07692	4450.76923	4521.59486	4165.64103	4217.94872	4111.28205	4331.28205	4064.10256	1696	1691	1237.705	0	0	0	0
19:02:33	25	0	0	0	4183.58974	4234.61539	4171.28205	4134.35897	3790.25641	3889.23077	3942.05128	4450.76923	4514.35897	4166.66667	4221.02564	4114.35897	4331.28205	4061.53846	1697	1690	1238.018	0	0	0	0
19:02:34	97	0	0	0	4167.69313	4288.20513	4169.23077	4138.97436	3793.84615	3889.23077	3940	4450.76923	4521.59486	4170.25641	4215.89744	4112.30769	4324.61539	4058.97436	1696	1690	1238.58	0	0	0	0
19:02:35	8	0	0	0	4165.12621	4286.20513	4164.10256	4136.46154	3789.97436	3886.66667	3936.92308	4446.66667	4519.59486	4169.23077	4218.97436	4112.82051	4326.66667	4061.53846	1696	1691	1238.997	0	0	0	0
19:02:36	116	0	0	0	4168.66154	4291.30769	4169.23077	4138.48718	3792.30769	3889.23077	3940	4449.74359	4519.48718	4167.79436	4112.82051	4325.64103	4058.46154	1697	1690	1239.738	0	0	0	0	
19:02:37	27	0	0	0	4168.20513	4283.58974	4167.69231	4138.97436	3791.79487	3885.64103	3933.84615	4449.23077	4522.5641	4169.23077	4221.4359	4114.8718	4329.74359	4061.02564	1696	1691	1240.051	0	0	0	0
19:02:38	67	0	0	0	4165.12621	4280.51282	4169.23077	4141.53846	3797.4359	3891.79487	3941.02564	4446.66667	4518.97436	4167.69231	4217.4359	4114.35897	4323.58974	4060	1691	1240.364	0	0	0	0	
19:02:39	107	0	0	0	4168.1795	4290.25641	4165.12621	4140.51282	3790.25641	3885.64103	3942.05128	4447.13949	4519.48718	4165.64103	4211.4359	4115.89744	4331.28205	4063.58974	1697	1691	1240.676	0	0	0	0
19:02:40	26	0	0	0	4163.07692	4283.58974	4166.15385	4135.38462	3788.20513	3889.23077	3938.97436	4450.25641	4517.4359	4165.64103	4221.53846	4116.92308	4334.35897	4061.53846	1697	1690	1241.392	0	0	0	0
19:02:41	70	0	0	0	4169.23077	4273.33333	4166.15385	4136.41026	3791.28205	3889.23077	3938.97436	4450.25641	4517.4359	4165.64103	4221.53846	4116.92308	4334.35897	4061.53846	1696	1691	1241.709	0	0	0	0
19:02:42	110	0	0	0	4153.84615	4286.15385	4170.25641	4141.02564	3792.82051	3887.17949	3937.94872	4449.92308	4518.97436	4165.64103	4220.51282	4114.8718	4329.74359	4063.07692	1695	1692	1241.993	0	0	0	0
19:02:43	21	0	0	0	4163.58974	4296.41026	4174.35897	4140.51282	3794.35897	3889.23077	3944.10256	4449.74359	4518.97436	4165.64103	4220.51282	4114.8718	4329.74359	4063.07692	1696	1691	1242.022	0	0	0	0
19:02:44	4	0	0	0	4163.07692	4274.8718	4170.25641	4137.4359	3791.79487	3888.20513	3940.51282	4449.74359	4520.51282	4166.15385	4222.02564	4116.92308	4327.17949	4063.07692	1696	1690	1242.897	0	0	0	0
19:02:45	112	0	0	0	4173.84615	4294.35897	4169.23077	4139.48718	3792.82051	3888.7195	3940	4451.79487	4518.97436	4166.15385	4221.02564	4113.33333	4326.66667	4061.02564	1696	1690	1243.741	0	0	0	0
19:02:46	27	0	0	0	4177.4359	4293.84615	4173.33333	4140	3795.8462	3889.74359	3940.51282	4450.76923	4520.51282	4164.61539	4221.02564	4113.84615	4324.10256	4056.92308	1696	1691	1244.085	0	0	0	0
19:02:47	83	0	0	0	4167	4284.10256	4171.79487	4141.53846	3790.6923	3885.12621	3940.51282	4450.76923	4520.51282	4168.1795	4218.97436	4117.4359	4324.10256	4058.46154	1696	1691	1244.574	0	0	0	0
19:02:48	127	0	0	0	4178.9736	4304.10256	4169.23077	4140	3795.8462	3889.74359	3942.05128	4448.74359	4518.97436	4168.1795	4220.51282	4112.30769	4328.7195	4064.10256	1697	1690	1245.463	0	0	0	0
19:02:49	74	0	0	0	4161.53846	4304.10256	4169.23077	4140	3795.8462	3889.74359	3942.05128	4448.74359	4518.97436	4168.1795	4220.51282	4112.30769	4328.7195	4064.10256	1697	1690	1246.463	0	0	0	0
19:02:50	114	0	0	0	4168.20513	4282.05128	4166.66667	4135.89744	3793.3333	3890.76923	3940.51282	4448.74359	4517.4359	4170.6923	4220.51282	4113.89744	4327.17949	4058.46154	1696	1690	1246.857	0	0	0	0
19:02:51	25	0	0	0	4158.96154	4264.61539	4171.9487	4141.02564	3796.41026	3895.38462	3944.10256	4448.74359	4517.4359	4170.6923	4220.51282	4113.89744	4326.92308	4063.07692	1696	1691	1246.774	0	0	0	0
19:02:52	53	0	0	0	4173.33333	4289.74359	4168.20513	4139.48718	3792.82051	3894.8718	3940.51282	4451.28205	4517.4359	4169.23077	4220.51282	4115.38462	4324.61539	4061.53846	1696	1692	1246.307	0	0	0	0
19:02:53	93	0	0	0	4171.28205	4306.15385	4169.48718	4140	3792.30769	3890.25641	3938.46154	4449.23077	4518.46154	4167.79436	4222.5641	4115.38462	4327.69231	4063.58974	1696	1691	1246.619	0	0	0	0
19:02:54	4	0	0	0	4159.48718	4302.05128	4169.74359	4135.38462	3794.8718	3892.30769	3940	4451.28205	4520	4166.15385	4221.53846	4119.48718	4329.74359	4062.5641	1696	1690	1246.932	0	0	0	0
19:02:55	76	0	0	0	4183.58974	4298.46154	4167.17949	4133.84615	3791.79487	3888.7195	3938.41026	4451.28205	4519.48718	4167.69231	4223.07692	4114.8718	4336.41026	4064.61539	1695	1691	1247.496	0	0	0	0
19:02:56	116	0	0	0	4177.94872	4284.8718	4170.6923	4143.58974	3794.35897	3896.92308	3943.58974	4448.7195	4517.94872	4168.1795	4218.46154	4116.41026	4327.5641	4063.05128	1696	1690	1247.809	0	0	0	0
19:02:57	99	0	0	0	4156.92308	4286.66667	4167.17949	4140	3792.30769	3889.74359	3938.46154	4449.74359	4515.89744	4168.1795	4221.53846	4116.41026	4321.53846	4063.07692	1696	1690	1248.685	0	0	0	0
19:02:58	46	0	0	0	4165.12621	4289.74359	4166.66667	4131.79487	3788.7195	3889.23077	3936.41026	4449.23077	4520	4167.17949	4221.53846	4121.02564	4328.7195	4062.5641	1696	1691	1248.778	0	0	0	0
19:02:59	86	0	0	0	4157.94872	4331.28205	4172.30769	4141.02564	3794.8718	3893.84615	3942.5641	4451.28205	4517.94872	4167.69231	4223.58974	4118.97436	4327.69231	4063.07692	1696	1691	1248.991	0	0	0	0
19:03:00	126	0	0	0	4178.9736	4295.38462	4166.66667	4138.97436	3791.28205	3892.30769	3940	4450.25641	4516.92308	4165.12621	4220.51282	4118.97436	4327.69231	4060.51282	1696	1691	1249.303	0	0	0	0
19:03:01	37	0	0	0	4172.30769	4286.66667	4165.64103	4136.41026	3789.23077	3890.25641	3938.41026	4448.20513	4521.59486	4167.69231	4221.02564	4113.84615	4331.28205	4060.51282	1695	1691	1250.216	0	0	0	0
19:03:02	85	0	0	0	4191.28205	4309.23077	4170.76923	4136.41026	3793.84615	3892.82051	3940	4450.76923	4518.46154	4166.66667	4219.48718	4116.41026	4328.7195	4062.05128	1696	1691	1250.592	0	0	0	0
19:03:03	125	0	0	0	4169.23077	4301.02564	4171.79487	4141.53846	3791.79487	3893.84615	3938.97436	4453.33333	4518.97436	4166.66667	4221.53846	4116.92308	4325.12621	4059.48718	1696	1690	1250.904	0	0	0	0
19:03:04	36	0	0	0	4177.4359	4290.76923	4166.66667	4135.38462	3787.17949	3891.28205	3938.41026	4451.28205	4518.97436	4167.69231	4221.53846	4117.94872	4331.28205	4061.53846	1696	1691	1251.217	0	0	0	0
19:03:05	76	0	0	0	4168.20513	4282.05128	4170.6923	4143.07692	3794.8718	3893.84615	3946.12621	4449.23077	4519.48718	4168.1795	4221.53846	4118.46154	4323.58974	4063.58974	1696	1691	1251.53	0	0	0	0
19:03:06	116	0	0	0	4155.64103	4303.07692	4169.74359	4132.82051	3790.6923	3891.79487	3940	4446.66667	4520.51282	4169.23077	4223.07692	4116.41026	4330.76923	4063.58974	1696	1690	1251.843	0	0	0	0
19:03:07	27	0	0	0	4153.84615	4295.38462	4169.23077	4135.38462	3793.33333	3890.25641	3942.05128	4450.25641	4520	4170.25641	4222.5641	4118.97436	4329.23077	4063.07692	1695	1692	1252.155	0	0	0	0
19:03:08	67	0	0	0	4159.48718	4274.8718	4172.30769	4140.25641	3792.5641	3897.4359	3946.12621	4452.30769	4520.51282	4167.17949	4221.53846	4120	4324.61539	4060.51282	1697	1689	1252.468	0	0	0	0
19:03:09	111	0	0	0	4151.38462	4274.8718	4172.30769	4138.97436	3793.84615	3897.4359	3946.12621	4447.69231	4520.51282	4167.17949	4221.53846	4115.89744	4325.64103	4061.02564	1696	1691	1252.818	0	0	0	0
19:03:10	62	0	0	0	4170.76923	4302.5641	4167.17949	4137.4359	3788.7195	3891.28205	3938.97436	4448.7195	4519.48718	4166.15385	4221.53846	4115.89744	4331.79487	4061.02564	1697	1691	1253.438	0	0	0	0
19:03:11	102	0	0	0	4172.82051	4302.05128	4171.28205	4141.02564	3793.84615	3896.41026	3943.58974	4450.25641	4518.97436	4166.66667	4220	4113.84615	4324.61539	4061.53846</							



## Anexo B: Hoja de Consentimiento para realizar los Experimentos

En la Figura 50 se presenta un ejemplo de la hoja de consentimiento informativo, presentado a cada uno de los participantes antes de realizar los experimentos.

### Hoja de Consentimiento Informado

Usted ha sido invitado/a a participar en una investigación sobre el uso de redes de sensores corporales para detectar estrés o fatiga durante la simulación de la conducción de un vehículo.

Esta investigación es dirigida por la Dra. María Reyes Muñoz y realizada por la alumna de doctorado Patricia Becerra Sánchez y la alumna invitada de estancia Ruth Elizabeth Aldama Rosas.

El propósito de esta investigación es detectar mediante señales electroencefalográficas (EEG) altos niveles de estados de estrés o fatiga que pudieran causar accidentes de tráfico.

Si acepta participar en esta investigación, se le solicitará:

- Evitar tomar durante las 24hrs. previas al experimento medicamentos que contengan sustancias que puedan producir sueño.
- Evitar el consumo de alcohol y/o drogas durante las 24Hrs. previas al experimento

Participar en este estudio le tomará aproximadamente 40 min. Durante la sesión se le colocará un sensor en la cabeza para recoger las señales EEG y es posible que se requiera tomar pruebas como fotografías, audio o video para completar la investigación.

Los datos que se recojan en el experimento serán utilizados únicamente con el fin de detectar posibles estados de estrés durante la tarea de conducción del vehículos.

### Riesgos

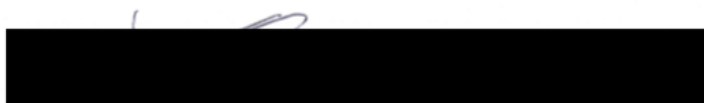
En la recolección de datos se usará un dispositivo para obtener señales EEG. Este dispositivo es totalmente inofensivo y no conlleva riesgo alguno para quien lo usa, no envía electricidad al cerebro ni al cuerpo. Es totalmente seguro de usar cuantas veces lo desee.

### Confidencialidad

Para la investigación, la identidad del participante no es relevante, lo único importante es la información que se obtengan del dispositivo EEG, así como otros datos (edad, sexo, etc). Toda información o datos que se obtengan del participante serán utilizados únicamente con fines de investigación y publicar en una revista de investigación.

### Derechos

Si ha leído este documento y ha decidido participar, por favor entienda que su participación es completamente voluntaria y que usted tiene derecho a abstenerse de participar o retirarse del estudio en cualquier momento. Su firma en este documento significa que ha decidido participar después de haber leído la información presentada en esta hoja de consentimiento.



Firma y nombre del Participante

Figura 50 Acuerdo presentado a cada participante antes de iniciar los experimentos





