# Clasificación por SVM utilizando FFT, DWT y DCT para modelo predictivo de estrés

S.D. Francisco Xavier Maestría en ciencias en microelectrónica aplicada, Instituto Politécnico Nacional ESIME Culhuacá,n 07320. Ciudad de México, México fsanchezd2300@alumno.ipn.mx

Dr. S. A. Jorge Ingeniería electrónica Tecnológico de estudios superiores de Chalco 56600 Edo. de México, México 0000-0003-3432-4305 Dr. E. H. Enrique Maestría en ciencias en microelectrónica aplicada, Instituto Politécnico Nacional ESIME Culhuacán 07320 Ciudad de México, México 0000-0002-4832-8270 Dr. S. G. Juan Carlos Maestría en ciencias en microelectrónica aplicada, Instituto Politécnico Nacional ESIME Culhuacán 07320 Ciudad de México, México 0000-0001-9746-7157

Abstracto — La clasificación y regresión por Máquinas de Soporte Vectorial SVM es utilizado en algoritmos de aprendizaje, procesamiento de señales, aplicaciones médicas, entre otros. Este trabajo presenta un estudio comparativo entre técnicas de procesamiento como la Transformada Rápida de Fourier FFT, la transformada de Wavelets DWT y la Transformada de Coseno Discreto DCT. Se utilizarán 5 canales para la obtención de la actividad cerebral mediante electroencefalograma EEG, qué posterior se llevarán a un sistema gestor de base de datos para su etapa de pre-procesado, procesamiento y almacenamiento. La adquisición de datos respecto a la actividad cerebral será con apoyo del sistema Emotiv, para una actividad cerebral relajada se considera escuchar música clásica a una frecuencia baja de 528 Hz. Para los datos en estado estresantes se toma en consideración el conjunto de test entre Stroop, el test de Raven, test psicotécnicos, imágenes orientadas a algún tipo de fobia y sonidos a frecuencia alta entre 2,500 a 5,500 Hz.

#### Palabras clave — Máquinas de Soporte Vectorial, Transformada Rápida de Fourier, Transformada de Cosenos, Transformada Wavelets, Procesamiento.

# I. INTRODUCCIÓN

Los ritmos cerebrales u ondas típicas se distinguen por diferentes frecuencias. Los límites de cada señal están dados por: Delta: menos de 4 Hz, entre 0.5 - 4 Hz; Theta: 4 -7.5 Hz; Alfa: 8 Hz - 15 Hz u 8 - 13 Hz; Beta: 15 Hz - 30 Hz o 14 - 30 Hz; Gamma: mayor a 30 Hz, 30 - 50 Hz, 50 - 70 Hz o entre 70 - 90 Hz [3][4]. En este artículo se consideran las frecuencias referentes a las investigaciones [3][4] con el fin de lograr la clasificación de las señales usando máquinas de soporte vectorial e implementando diferentes técnicas de análisis, entre ellas la transformada rápida de Fourier, transformada de cosenos y transformada wavelets.

Estos datos de EEG se traducen en lo general a bandas de longitud de onda, que posteriormente se utilizan para crear vectores de trabajo. La técnica de gestión de clase sugerida implica la eliminación, selección y clasificación de funciones en las categorías de objetos y métodos, para el procesamiento de las señales y clasificación se opta por utilizar:

La Transformada de Coseno Discreto (DCT): Compacta la mayor parte de la energía de la señal original, es decir, se puede describir como una representación en pocos puntos de

datos en una zona específica para un análisis con una mayor cantidad de información de la señal original [21].

Transformada Rápida de Fourier (FFT): Una vez que los datos se registran en el dominio del tiempo, en esta se calculan los componentes de frecuencia de la señal, este algoritmo reduce la complejidad de la transformada discreta de Fourier (DCT) y es utilizada en una amplia área de aplicaciones (procesamiento de audio, comprensión de datos, etc.), pero difiere en la parte real que proporciona DCT [11][20].

La Transformada de Wavelets (DWT): Es una técnica que descompone las señales en diferentes componentes espectrales que permite obtener información en frecuencias bajas y altas (componentes de aproximación y detalle), y a su vez proporciona un análisis detallado basado en los componentes de estas frecuencias [21].

El algoritmo de clasificación por máquinas de soporte vectorial (SVM): Se basa en hallar un hiperplano dentro de un conjunto de datos o clases, así, separándolos para el desarrollo del modelo de aprendizaje. Comúnmente es utilizado para el reconocimiento de voz, imágenes, procesamiento de señales y diagnóstico médico [17].

El propósito de este análisis es presentar un estudio comparativo y determinar qué método es más adecuado para un uso menor de recursos computacionales, e incluso para dispositivos portátiles, ya que se utilizan variables que determinan a cada modelo como precisión, exactitud, sensibilidad, especificidad, promedio ponderado de precisión (F1, evalúa el rendimiento del modelo utilizando precisión y el recall), la tasa de verdaderos positivos (recall exhaustividad), además de diferentes funciones 0 matemáticas para cada modelo de clasificación y regresión que consumen gran cantidad de memoria y procesamiento [11][20]. Este trabajo presenta los procesos de obtención, preprocesamiento, procesamiento y extracción de características de la actividad eléctrica del cerebro por medio del EEG con una duración de 120 segundos en 7 participantes sin problemas cerebrovasculares, hombres mayores de edad entre 18-30 años. Las muestras de la actividad eléctrica cerebral de cinco participantes serán

utilizadas para el análisis y clasificación del modelo, los dos restantes serán utilizadas para identificar el estrés provocado por los test, a través del modelo desarrollado. El equipo a utilizar será el EEG de EMOTIV que se enfoca en reconocer eventos eléctricos cerebrales, estos se representan en diferentes amplitudes que proporcionan sus canales en la zona prefrontal (AF4, AF), en la zona apófisis mastoidea con el electrodo sentido de modo común (CMS por sus siglas en inglés) ubicado en el lóbulo temporal derecho (T7), pierna derecha impulsada (DRL por sus siglas en inglés), el electrodo pasivo en la zona temporal derecha (T8) además los electrodos T7 y T8 forman un circuito de retroalimentación que impulsa el potencial promedio del sujeto, por último el electrodo común o tierra (GND) ubicado en la zona parietal (Pz). Estos canales miden la diferencia de potencial en los electrodos activos respecto al electrodo de referencia y uno adicional como electrodo común o tierra [12].

Bajo este esquema, que se considera una técnica no invasiva para adquirir datos de la actividad eléctrica cerebral, esta determina por el sistema internacional 10/20, qué proporciona la ubicación de cada electrodo, separación entre los mismos y nomenclatura [12], ya que es un método accesible, rápido e inclusive en costos es relativamente menor en comparación con la tomografía por emisión de positrones (PET), la resonancia magnética funcional (FMRI), electrooculograma (EOG), reflejo galvánico de la piel (GSR) y de espectroscopia funcional de infrarrojo cercano (fNIRS) [5][6][9].

Esta información obtenida se llevará a un sistema de gestión de base de datos (SGBD) con la finalidad de llevar a cabo el procesamiento, la cual está ubicada en GitHub [24].

# II. METODOLOGÍA

#### A. Sistema internacional 10/20

Para adquirir los datos necesarios en el presente análisis se usará como base el sistema internacional 10/20 (figura 1)



Fig. 1. Representación de la nomenclatura 10/20 [1]

que orienta la posición de los electrodos extracraneales, lo cual cuenta con una nomenclatura que señala el área (Fp, prefrontal; F, frontal; C, central; P, parietal; T, temporal; O, occipital y Z, línea media o línea cero), mientras que los números designan el hemisferio (pares del derecho, impares del izquierdo) [12]. La distancia de cada electrodo es separada en un 10% a 20% respecto a la distancia total entre nasión a inión.

#### B. Sistema EMOTIV

Para la adquisición de la actividad cerebral se utiliza el sistema EMOTIV de cinco canales que consta de un diseño previamente adaptado al sistema internacional 10/20 que a su vez facilita la ubicación de cada electrodo en distintas personas.



Fig. 2. Nomenclatura y ubicación de los electrodos [2]

El área de los electrodos prefrontales en el sistema EMOTIV (figura 2) están ubicados en las zonas AF4 y AF3, los electrodos de referencia y protección CMS/DLR (*Common Mode Sense/Driven Right Leg*) ubicados en T7 y T8, el electrodo común o tierra está ubicado en Pz [14]. Cuenta con una frecuencia de muestreo de 128 muestras por segundo en cada canal, un filtro de quinto orden, una resolución de 16 bits e integra 9 ejes (tabla 1).

N h	Emotiv insight 5 canales			
Nombre	Caracte	rísticas	Descripción	
Canales/electrodos	5 canales (AF3, AF4, T7, T8, Pz).	Referencias en CMS/DRL y de protección.	Electrodos activos ubicados en el lóbulo prefrontal, los de referencia en temporal y común en parietal.	
Señal EEG	128 muestras por segundo a una respuesta de frecuencia entre 0.5-43Hz.	Filtro de 5a orden (Sinc).	Sensor cubierto de goma de polímero semiseco hidrófilo.	
Potencia	Batería interna de 480 mA.		Con una duración aproximada de 20 h.	
Comunicación	Bluetooth.		Bluetooth. 5.0	
Sensores/IMU	9 ejes. 16 bits.	Acelerómetro, giroscopio y magnetómetro	ICM-20948 Ace.+/-8 g Gir.+/-2000 dps Mag.+/-12 gauss.	
Detectores	Expresiones faciales.	Métricas de rendimiento	Rendimiento a analizar como estrés, relajación v concentración	

# C. Obtención de muestras

Utilizando el software oficial de EMOTIV [15] que establece una comunicación de punto a punto por medio de Bluetooth 5.0, además permite la opción de establecer la comunicación desde dispositivos portátiles o PC. Para adquirir las muestras o eventos de potencial evocado (ERP), se dispone con una interfaz intuitiva (figura 4) que permite acceder, grabar y exportar las muestras de la actividad cerebral a un archivo .csv. Cabe mencionar que se optó por

una cuenta de un mes para estudiante, sin ella no es posible obtener los datos.

A pesar de contar con un diseño previo (figura 3 (a)), este es necesario de un ajuste mínimo para que abarque en las zonas establecidas por la nomenclatura, al ser necesario se lubrican los electrodos con un poco de solución salina (H<sub>2</sub>O + ClNa --> NaOH + HCL) [16], además se les pidió adoptar la posición de sedente, posterior es vincular la conexión por medios no guiados (Bluetooth) con el dispositivo a un equipo o PC. Sin más detalle, se utiliza la ventana de calidad de contacto del mismo software para alcanzar un porcentaje de calidad mayor a 90%; este valor de calidad lo establece el propio fabricante (figura 3 (b)).



Fig. 3. a) Equipo Emotiv 5 canales; b) Calidad de contacto

Al tener la calidad deseada, el siguiente paso es grabar los datos estresantes a través de la combinación de tres test: El test de Raven: Donde cada reactivo consiste en relacionar el número con la imagen correspondiente de acuerdo con el patrón de la imagen (figura 5) [31]; Test de Stroop: que consiste en seleccionar el color con cada inciso, dicho inciso será interpretado o escrito con el nombre del mismo color pero representado con un distinto tono [32]; Test psicotécnicos: Abarca la resolución del patrón de una imagen y relacionarlo con las opciones disponibles [33] (figura 6), además de incluir algunas fobias representadas en imágenes (figura 7) al momento de solucionar el test [29][30], e inclusive se incluyen 3 audios que se han considerado estresantes que van a una frecuencia a partir de 2.5 a 5.5 kHz [27][28]. Al finalizar los 120s, el mismo software guarda la actividad cerebral, para después exportarlos con la extensión .csv [16].



Fig. 4. Datos de diversos canales, diferentes ubicaciones de cada electrodo y potencia de banda de Alpha, Beta y Theta (Proporcionado por EMOTIV) [25]



Fig. 5. Test de Raven



Fig. 6. Test de Stroop y prueba psicotécnica



Fig. 7. Tripofobia (una de las imágenes que se utilizó para causar el estrés en combinación al test)

Para adquirir las muestras relajantes se sometieron a los participantes a escuchar música clásica, utilizando la pieza de F. Chopin, *Nocturne* en do sostenido menor para violín y piano [19], además de pedirles que adoptaran la posición *Fowler* elevada (sedente) y a su vez cerrar los ojos después de los primeros 30s, al finalizar los 120s se les pide abrir los ojos y retirar el sistema EMOTIV. Por último, el archivo .csv proporcionado por el sistema (figura 8) genera los datos de amplitud de cada canal respecto al tiempo. La columna B se toma como tiempo, mientras E, F, G, H y I establecen la amplitud para cada canal.

1	A	В	С	D	E	F	G	Н	1	
1	title:estres	start timest	stop timest	headset typ	headset set	headset firm	channels:53	sampling ra	samples:16	1
2	Timestamp	OriginalTime	EEG.Counte	EEG.Interpo	EEG.AF3	EEG.T7	EEG.Pz	EEG.T8	EEG.AF4	E
3	1.696E+09	1.696E+09	111	0	4275.5127	4257.9487	4127.1797	4184.7437	4243.8462	
4	1.696E+09	1.696E+09	112	0	4276.2822	4265.2563	4116.4102	4190.1284	4246.2822	
5	1.696E+09	1.696E+09	113	0	4268.4614	4305.769	4123.2051	4182.436	4261.7949	
6	1.696E+09	1.696E+09	114	0	4273.2051	4352.1797	4131.1538	4168.2051	4261.5386	
7	1.696E+09	1.696E+09	115	0	4285.769	4335.3848	4121.1538	4181.4102	4256.5386	
8	1.696E+09	1.696E+09	116	0	4272.0513	4259.4873	4114.231	4189.231	4262.564	
9	1.696E+09	1.696E+09	117	0	4236.9229	4221.1538	4109.231	4147.436	4239.8716	
10	1.696E+09	1.696E+09	118	0	4220.1284	4253.3335	4096.0259	4116.1538	4201.5386	
11	1.696E+09	1.696E+09	119	0	4229.8716	4287.564	4099.231	4143.4614	4215.5127	
12	1.696E+09	1.696E+09	120	0	4251.0259	4301.2822	4119.1025	4171.0259	4254.7437	
13	1.696E+09	1.696E+09	121	0	4276.0259	4322.436	4128.0771	4175.3848	4261.6665	
14	1.696E+09	1.696E+09	122	0	4288.3335	4329.6152	4137.564	4185.6411	4267.436	
15	1.696E+09	1.696E+09	123	0	4280.2563	4307.1797	4154.1025	4182.1797	4284.8716	
16	1.696E+09	1.696E+09	124	0	4275.1284	4289.7437	4150.1284	4168.5898	4279.231	
17	1.696E+09	1.696E+09	125	0	4277.9487	4291.7949	4133.9741	4185.5127	4267.1797	
18	1.696E+09	1.696E+09	126	0	4268.8462	4303.9741	4130.2563	4195.8975	4262.8203	
19	1.696E+09	1.696E+09	127	0	4260.8975	4314.1025	4132.3076	4169.3589	4250.1284	
20	1.696E+09	1.696E+09	0	0	4273.7178	4299.231	4137.8203	4166.5386	4250.6411	
21	1.696E+09	1.696E+09	1	0	4280.5127	4279.8716	4141.5386	4188.7178	4265.8975	
22	1.696E+09	1.696E+09	2	0	4268.3335	4293.2051	4132.1797	4178.5898	4259.4873	
23	1.696E+09	1.696E+09	3	0	4267.9487	4307.1797	4127.9487	4160.769	4248.9741	
24	1.696E+09	1.696E+09	4	0	4275.8975	4302.1797	4127.8203	4163.2051	4250.5127	
25	1.696E+09	1.696E+09	5	0	4266.4102	4306.9229	4109.6152	4155.8975	4237.9487	
26	1.696E+09	1.696E+09	6	0	4260.8975	4291.1538	4100.8975	4147.3076	4232.0513	
27	1.696E+09	1.696E+09	7	0	4272.436	4248.7178	4114.8716	4155	4250.8975	
28	1.696E+09	1.696E+09	8	0	4273.9741	4267.1797	4111.2822	4161.4102	4251.0259	
29	1.696E+09	1.696E+09	9	0	4269.1025	4323.0771	4100.5127	4173.7178	4237.564	
30	1.696E+09	1.696E+09	10	0	4274.1025	4308.4614	4113.4614	4188.9741	4248.2051	
31	1.696E+09	1.696E+09	11	0	4272.0513	4270.1284	4122.3076	4184.4873	4260	
32	1.696E+09	1.696E+09	12	0	4267.8203	4274.1025	4115.8975	4184.1025	4264.8716	
33	1.696E+09	1.696E+09	13	0	4279.6152	4257.436	4117.9487	4194.6152	4287.564	
34	1.696E+09	1.696E+09	14	0	4285	4230.1284	4118.3335	4185.8975	4305.8975	
35	1.696E+09	1.696E+09	15	0	4269.6152	4263.4614	4104.231	4176.5386	4298.5898	
36	1.696E+09	1.696E+09	16	0	4252.9487	4300.8975	4087.3076	4175.1284	4286.2822	
37	1.696E+09	1.696E+09	17	0	4247.3076	4288.0771	4077.1794	4156.4102	4277.564	
îk	< 5 S	estres 1	INSIGHT2 196	300 2023.0	+	1070 700	1000 0107		1076 7010	

Fig. 8. Tabla de los datos que proporciona el sistema con extensión .csv

#### III. ALMACENAMIENTO DE DATOS

Los valores son leídos y enviados a un sistema de gestión de base de datos creada en la plataforma MariaDB para su almacenamiento, localización y registro de cada individuo participante (figura 9).

Field	Type	Null	Key		Default	Extra
стем	int(11)	YES	1	Ì	NULL	i I
ID	double(8,1)	NO	1	1	NULL	I.
P1_1	decimal(18,11)	YES	1	1	NULL	1
P1_2	decimal(18,11)	YES	T.	Ĩ.	NULL	1
P1_3	decimal(18,11)	YES	Ĩ.	-T	NULL	Ĩ
P1_4	decimal(18,11)	YES	1	1	NULL	I.
P1_5	decimal(18,11)	YES	1		NULL	1
P1_6	decimal(18,11)	YES	T.	1	NULL	Ĩ.
P1_7	decimal(18,11)	YES			NULL	1
P1_8	decimal(18,11)	YES	1		NULL	1
P1_9	decimal(18,11)	YES			NULL	1
P1_10	decimal(18,11)	YES	T.		NULL	T.
P1_11	decimal(18,11)	YES	1	1	NULL	1
P1_12	decimal(18,11)	YES	1	1	NULL	1
P1_13	decimal(18,11)	YES	1		NULL	1
P1_14	decimal(18,11)	YES	T		NULL	I
P1_15	decimal(18,11)	YES			NULL	1

Fig. 9. Base de datos de las muestras en estado de relajación y estructura de la misma

#### IV. FILTRADO DE DATOS

El filtrado consiste en aplicar un filtro digital con una ventana tipo *Hamming* con un orden de 100 coeficientes (figura 10) que consta de un pasa bajas a una frecuencia de corte de 64 Hz y un pasa altas con una frecuencia de corte a partir de 0.5 Hz, estos valores se consideran a las frecuencias referentes a las investigaciones [3][4] y a la tasa de muestreo del modelo EMOTIV insight.



Fig. 10. Filtro digital normalizado (ventana Hamming)

# V. ANÁLISIS UTILIZANDO DWT, FFT, DCT, EXTRACCIÓN Y CLASIFICACIÓN DE INFORMACIÓN

En la muestra del canal AF3 (figura 11) se representa el canal con el filtro de 5a orden establecido por el mismo sistema EMOTIV (Canal). Seguidamente, se aplica el filtrado de ventana Hamming (Señal con ventana Hamming), posteriormente se realiza la transformada wavelets (Señal con ventana y wavelet) que conserva los componentes de baja frecuencia o coeficientes de aproximación, los parámetros que se han usado en la transformada son, db4, method Bayes y level 3 [21][22] que se han usado en diversas aplicaciones como señales de voz, señales fisiológicas, señales ECG, entre otras. Para la configuración ideal u óptima de este análisis, se requiere de una ardua investigación y comparación de diferentes técnicas de la transformada de ondeletas (wavelets), es decir, estos parámetros utilizados (db4, method Bayes y level 3) dan una aproximación aceptable (tabla 5) en relación con diversas investigaciones que han utilizado los parámetros mencionados, como en [26] donde realizan la comparación de diferentes técnicas para distinguir el trastorno anormal del desarrollo neurológico (TDHA, trastorno del espectro autista, depresión, enfermedades mentales, etc.), donde el method Bayes presentó un mejor rendimiento de AUC (área de la característica operativa del receptor).



Fig. 11. DWT, filtro ventana Hamming y señal cruda del canal AF3

La transformada rápida de Fourier es un algoritmo que reduce la complejidad de la transformada discreta de Fourier (DFT), siendo una de las más utilizadas para el análisis de señales, respuesta en frecuencia, modulación, codificación, etc.

En el análisis se comparará con DWT, DCT y combinaciones de las mismas para obtener la mayor precisión posible y el modelo SVM con menor complejidad matemática.

Previamente concluida con la etapa de preprocesamiento, se aplica FFT a la señal (figura 12).



La transformada de cosenos discreto, por sus propiedades que mantiene gran parte de la energía de la señal original, ayuda a un análisis con valores más cercanos a la muestra original, ya que en la mayoría de los datos o señales (biomédicas, señales de audio, entre otras) no representan el complejo imaginario y esta opción es atractiva para comparar ante las demás transformadas.

De igual forma, aplicando un preprocesamiento previo a las señales adquiridas, se aplica DCT al final (figura 13).



Fig. 13. DCT del canal AF3

Para la extracción de características (figura 14) se aplica un bucle con una longitud de 847x20 valores para cada canal y un total de 5 grupos por persona.



Fig. 14. A) Extracción de características DCT; B) Extracción de características de DWT

Seguidamente, la clasificación por SVM será utilizada para desarrollar el modelo, ya que opera con un gran número de

campos de predictor, es decir, correlaciona datos de forma que logra caracterizarlo, con ello las características de los nuevos datos entrantes pueden ser predictivas. Cada grupo clasificado es separado por un hiperplano mediante las funciones matemáticas (lineal, cuadrática, cúbica, etc.). Ya que cada función utiliza algoritmos y parámetros distintos, se experimenta con los distintos modelos para obtener el mejor modelo.

Al aplicar el proceso mediante FFT, TWD y DCT se realiza la clasificación de cada individuo utilizando SVM [23] y comparar el resultado entre sí. El resultado del tren de datos a analizar son [23][22]:

Exactitud: Porcentaje de observaciones que están correctamente clasificadas; Costo total: clasificación total de dato erróneo; Tasa de error: Clasificaciones confusas; Velocidad de predicción: Velocidad que le lleva tomar a los nuevos datos de predicción; Tiempo de entrenamiento: Tiempo que le toma crear el modelo.

#### VI. RESULTADOS Y DISCUSIÓN

La mayor precisión que se obtuvo al separar cada canal y clasificarlos fue de una aproximación entre 80 al 100% en el canal 1 (AF3), seguidamente el canal 2 (T7) entre 50 al 80%, por último los canales restantes alcanzan una precisión entre 60 a 80%.

#### A. Utilizando el modelo de ventana Hamming y FFT

Los modelos que se utilizaron a base de máquinas de soporte vectorial y aplicando la transformada rápida de Fourier fueron a continuación (tabla 2):

N.	Comparativa entre modelos SVM				
	Tipo de modelo SVM	Precisión %	Costo total		
1	Lineal	100	0		
2	Cuadrada	82	9		
3	Cúbica	100	0		
4	Fina Gaussiana	100	0		
5	Media Gaussiana	88	6		
6	Robusta Gaussiana	72	14		

TABLA II. RESULTADOS DE MODELOS DEL CANAL AF3 CON SVM UTILIZANDO FFT

En la matriz de confusión (figura 15) el modelo SVM lineal, cúbica y fina Gaussiana obtuvieron una precisión aproximada al 100%, pero solo para el canal AF3, para los demás canales o combinación de los mismos se obtiene una precisión menor o igual al 65% (tabla 3).



Fig. 15. Matriz de confusión de modelo SVM lineal con FFT del canal AF3

 TABLA III.
 Resultados de modelos SVM utilizando FFT en combinación de todos los canales

N	Comparativa entre modelos SVM				
IN.	Tipo de modelo SVM	Precisión %	Costo total		
1	Lineal	65	87		
2	Cuadrada	48	128		
3	Cúbica	43	141		
4	Fina Gaussiana	60	100		
5	Media Gaussiana	60	100		
6	Robusta Gaussiana	56	110		

# B. Utilizando FFT y DWT

Utilizando los mismos modelos de SVM, pero lo que difiere es la transformada rápida de Fourier combinada con la transformada de wavelets (tabla 4)

N.	Comparativa entre modelos SVM						
	Tipo de modelo SVM	Precisión %	Costo total				
Canal AF3							
1	Lineal	100	0				
2	Cuadrada	54	23				
3	Cúbica	100	0				
4	Fina Gaussiana	98	1				
5	Media Gaussiana	100	0				
6	Robusta Gaussiana	100	0				
	Canal T7						
1	Lineal	50	25				
2	Cuadrada	70	15				
3	Cúbica	80	10				
4	Fina Gaussiana	78	11				
5	Media Gaussiana	70	15				
6	Robusta Gaussiana	72	14				
	Canal T8						

TABLA IV. RESULTADOS DE MODELOS SVM CON FFT Y DWT COMBINADOS

N.	Comparativa entre modelos SVM					
1.0	Tipo de modelo SVM	Precisión %	Costo total			
1	Lineal	62	19			
2	Cuadrada	58	21			
3	Cúbica	78	11			
4	Fina Gaussiana	74	13			
5	Media Gaussiana	72	14			
6	Robusta Gaussiana	56	22			
	Canal AF4					
1	Lineal	52	24			
2	Cuadrada	46	27			
3	Cúbica	78	11			
4	Fina Gaussiana	80	10			
5	Media Gaussiana	78	11			
6	Robusta Gaussiana	60	20			
	Canal Pz					
1	Lineal	58	21			
2	Cuadrada	46	27			
3	Cúbica	68	16			
4	Fina Gaussiana	72	14			
5	Media Gaussiana	64	18			
6	Robusta Gaussiana	64	18			

El modelo con mayor porcentaje ha sido SVM de tipo lineal, cúbica, media Gaussiana y robusta Gaussiana con una aproximación del 100% para el canal AF3.

Al combinar los canales proporcionan una precisión del 80% para el modelo SVM cuadrada (tabla 5) y una matriz de confusión con un 81% de datos correctamente clasificados y una tasa de error del 18% (figura 16).

 TABLA V.
 Resultados de modelos SVM con FFT y DWT en combinación de todos los canales

N	Comparativa entre modelos SVM				
IN.	Tipo de modelo SVM	Precisión %	Costo total		
1	Lineal	60	99		
2	Cuadrada	80	49		
3	Cúbica	51	122		
4	Fina Gaussiana	58	104		
5	Media Gaussiana	58	104		
6	Robusta Gaussiana	51	122		



ig. 16. Matriz de confusión SVM cuadrada de FFT y DWT combinación de todos los canales

# C. Utilizando el modelo de ventana Hamming

Al utilizar únicamente el modelo de ventana de tipo *Hamming* se observa el resultado en la tabla 6.

Los resultados obtenidos presentan una precisión entre 50 a 76% utilizando el modelo SVM media Gaussiana.

TABLA VI.Resultados con ventana Hamming para el canalT7

N.	Comparativa entre modelos SVM				
	Tipo de modelo SVM	Precisión %	Costo total		
1	Lineal	52	24		
2	Cuadrada	58	21		
3	Cúbica	60	20		
4	Fina Gaussiana	62	19		
5	Media Gaussiana	76	12		
6	Robusta Gaussiana	54	23		

El modelo con mayor porcentaje ha sido SVM de tipo media Gaussiana con un 76% de precisión para el canal T7.

En la matriz de confusión (figura 17) se combinan todos los canales, el modelo con mejor precisión fue SVM fina Gaussiana que tiene un 48% clasificados como relajados y un 52% en la tasa de falsos negativos por error.



Fig. 17. Matriz de confusión SVM lineal usando ventana *Hamming* en combinación de todos los canales

## D. Utilizando DWT

Los resultados con la transformada discreta de Wavelets se muestran en la tabla 7.

N.	Comparativa entre modelos SVM					
	Tipo de modelo SVM	Precisión %	Costo total			
Canal AF3						
1	Lineal	56	22			
2	Cuadrada	50	25			
3	Cúbica	64	18			
4	Fina Gaussiana	68	16			
5	Media Gaussiana	74	13			
6	Robusta Gaussiana	68	16			
	Canal T7					
1	Lineal	58	21			
2	Cuadrada	66	17			
3	Cúbica	64	18			
4	Fina Gaussiana	58	21			
5	Media Gaussiana	62	19			
6	Robusta Gaussiana	76	12			
	Canal T8					
1	Lineal	62	19			
2	Cuadrada	58	21			
3	Cúbica	78	11			
4	Fina Gaussiana	74	13			
5	Media Gaussiana	72	14			
6	Robusta Gaussiana	56	22			
	Canal AF4					
1	Lineal	50	25			
2	Cuadrada	50	25			
3	Cúbica	48	26			
4	Fina Gaussiana	46	27			
5	Media Gaussiana	64	18			
6	Robusta Gaussiana	52	24			
Canal Pz						
1	Lineal	52	24			
2	Cuadrada	40	30			
3	Cúbica	56	22			
4	Fina Gaussiana	52	24			
5	Media Gaussiana	66	17			
6	Robusta Gaussiana	52	24			

TABLA VIII.	RESULTADOS DE MODELOS SVM CON DWT
COM	IBINACIÓN DE TODOS LOS CANALES

N.	Comparativa entre modelos SVM		
	Tipo de modelo SVM	Precisión %	Costo total
1	Lineal	46	27
2	Cuadrada	48	26
3	Cúbica	50	25
4	Fina Gaussiana	58	21
5	Media Gaussiana	58	21
6	Robusta Gaussiana	60	20

La combinación de los canales proporciona una precisión del 60 % para SVM robusta Gaussiana (tabla 8).

## E. Utilizando DCT

Utilizando DCT se muestran los resultados en la tabla 9, el valor más relevante fue con una precisión de 74% con el canal Pz para el modelo SVM cuadrada, mientras que los demás canales y modelos varían entre 50 a 60%.

TABLA IX. RESULTADOS CON DCT DEL CANAL PZ

N.	Comparativa entre modelos SVM		
	Tipo de modelo SVM	Precisión %	Costo total
1	Lineal	58	21
2	Cuadrada	74	13
3	Cúbica	52	24
4	Fina Gaussiana	64	18
5	Media Gaussiana	50	25
6	Robusta Gaussiana	52	24

En la Matriz de confusión del modelo DCT (figura 18) muestra un 96% en clasificación relajada y una tasa de falsos negativos por error del 4%, pero un 76% de error para el caso cuando la clasificación obtiene un 24% como datos estresados en combinación de todos los canales.





# F. Utilizando FFT y DCT

Al combinar Fourier y la transformada de cosenos se obtuvo una precisión de 58% para el modelo SVM fina Gaussiana y media Gaussiana (tabla 10).

Para la matriz de confusión (figura 19) se obtuvo un resultado similar al utilizar solamente DCT, es decir, un estado (estresante o relajado) es clasificado correctamente hasta una precisión mayor al 90%, pero de igual forma realiza una clasificación errónea o semejante a los datos del estado anterior.

TABLA X. RESULTADOS CON FFT Y DCT CON LOS CANALES COMBINADOS

N	Comparativa entre modelos SVM		
	Tipo de modelo SVM	Precisión %	Costo total
1	Lineal	57	106
2	Cuadrada	56	109
3	Cúbica	50	125
4	Fina Gaussiana	58	104
5	Media Gaussiana	58	104
6	Robusta Gaussiana	52	118



Fig. 19. Matriz de confusión SVM fina Gaussiana y media Gaussiana usando FFT y DCT con canales combinados

# G. Utilizando DWT y DCT

TABLA XI.	RESULTADOS CON FFT Y DCT CON LOS CANALES
	COMBINADOS

N.	Comparativa entre modelos SVM		
	Tipo de modelo SVM	Precisión %	Costo total
1	Lineal	55	111
2	Cuadrada	68	80
3	Cúbica	50	124
4	Fina Gaussiana	58	103
5	Media Gaussiana	60	100
6	Robusta Gaussiana	51	121



Fig. 20. Matriz de confusión SVM cuadrada usando DWT y DCT con canales combinados

La combinación de DCT y DWT otorga una precisión de 68% (tabla 9) para el modelo SVM cuadrático, pero una tasa de falsos negativos por error aproximada del 50% (figura 20)

### H. Modelo predictivo

Los nuevos datos de las personas relajadas/estresadas se introducen en el modelo para definir su estado entre relajado y estresado (figura 21).

Para el modelo desarrollado se utilizan FFT y DWT combinadas, ya que obtuvieron una mejor precisión en la mayoría de los canales (R para relajado y S para estresado) con los modelos SVM cuadrada y lineal.

165 R	165	S	
166 R	166	S	
167 B	167	S	
168 R	168	S	
169 R	169	S	
170 R	170	S	
171 P	171	s	
172 5	172	S	
173 R	173	s	
174 R	174	S	
175 P	175	5	
175 K	176	s	
170 K	177	s	
177 5	1/8	s	
178 5	179	S	
179 5	180	s	
180 S	181	S	
181 R	182	5	
182 R	183	5	
183 R	184	5	
184 R	185	5	
185 R	186	S	
186 R	187	5	
187 R	188	S	
188 R	189	5	
189 R	190	5	
190 R	191	5	
191 R	192	5	

Fig. 21. a) Datos de actividad relajante etiquetados como relajados con el modelo predictivo con FFT y DWT; b) Datos estresados etiquetados como estresantes con el modelo predictivo.



La matriz de confusión (figura 22) muestra el porcentaje de precisión obtenido utilizando las transformadas FFT y DWT, ya que mostró con canales combinados un mejor rendimiento, además la precisión del modelo SVM cuadrada varía entre 78 a 83%.

La siguiente gráfica (figura 23) muestra la cantidad acertada de valores estresados (S) en relación con el modelo desarrollado.



Fig. 23. Gráfica relacionada con datos de actividad cerebral estresado y modelo desarrollado con SVM cuadrada

La gráfica con nuevos datos de estado relajado (figura 24) muestra la cantidad acertada de valores relajados (R) con relación al modelo desarrollado.



modelo desarrollado con SVM cuadrada

La gráfica con el modelo SVM lineal (figura 25) muestra la cantidad acertada para este modelo que obtuvo una precisión entre 60 a 66% (tabla 5).



Fig. 25. Gráfica relacionada con datos de actividad cerebral relajado y modelo desarrollado con SVM lineal

En la gráfica (figura 26) muestra los valores acertados de nuevos datos de la actividad cerebral en estado estresado, utilizando SVM lineal.



Fig. 26. Gráfica relacionada con datos de actividad cerebral estresado y modelo desarrollado con SVM lineal

## VII. CONCLUSIÓN

Al combinar los canales se obtiene una precisión del 80% (tabla 5), relativamente mayor que al tenerlos separados a excepción del canal AF3 utilizando FFT o en combinación con DWT, lo inconveniente de solo usar el canal AF3 es al momento de crear el modelo y someterlo a nuevos datos, que origina un error de clasificación entre 60% a 70%, en cambio, la clasificación (figura 16) de canales combinados proporcionan una mejor predicción (figura 23), a su vez los modelos con mayor rendimiento en precisión han sido SVM cuadrada y SVM lineal, en conjunto con la transformada rápida de Fourier y la transformada discreta de wavelets que otorgan una certeza aceptable. Por una parte, el modelo SVM lineal es menos complejo, ya que cuenta solo con operaciones de sumas lineales, así como también con multiplicaciones del mismo grado, siendo ideal en sistemas con recursos muy limitados para obtener mayor velocidad al desarrollar el modelo o con escasa memoria para almacenar los pesos y sesgos. En cambio, el modelo SVM cuadrada cuenta con un nivel de complejidad moderada, lo cual lo hace ideal para uso en sistemas con recurso computacional equilibrado con la posibilidad de modificar ciertos parámetros o componentes, como en memoria y optimizar algoritmos para el entrenamiento del modelo, así de igual forma otorgando mínimos ajustes sin sacrificar la precisión o certeza del modelo ante nuevos datos.

#### VIII. AGRADECIMIENTOS

Expreso mi generosa gratitud al IPN por el apoyo y orientación a través del conocimiento, instalaciones y equipo o herramientas de medición a lo largo del desarrollo del proyecto.

Deseo reconocer la generosa financiación otorgada por parte de Conachyt, a través de la beca de manutención por el estudio de posgrado, además de su influencia en mi enfoque y perfil de investigador.

#### IX. REFERENCIAS

[1] Fisiología de la actividad eléctrica del cerebro: electroencefalograma. (2019). Sistema internacional [imagen].

https://fisiologia.facmed.unam.mx/wpcontent/uploads/2022/09/7a\_2.png

[2] Basics of neural oscillations. (2024). Localización de sensores EEG [imagen].

https://d2z0k1elb7rxgj.cloudfront.net/uploads/2022/09/Sensors@3x-min-1024x1024.png

[3] M. Bandarabadi, C. A. Teixeira, B. Direito and A. Dourado (2012), "Epileptic seizure prediction based on a bivariate spectral power methodology," Annual International Conference of the IEEE Engineering in Medicine and Biology Society, San Diego, CA, USA, pp. 5943-5946, doi: 10.1109/EMBC.2012.6347347.

[4] A. Quintero-Rincón, C. D'Giano and H. Batatia (2020), "Musuppression detection in motor imagery electroencephalographic signals using the generalized extreme value distribution," International Joint Conference on Neural Networks (IJCNN), Glasgow, UK, pp. 1-5, doi: 10.1109/IJCNN48605.2020.9206862.

[5] J. -H. Han, S. Ji, C. Shi, S. -B. Yu and J. Shin (2015), "Recent progress of non-invasive optical modality to brain computer interface: A review study," *The 3rd International Winter Conference on Brain-Computer Interface*, Gangwon, Korea (South), pp. 1-2, doi: 10.1109/IWW-BCI.2015.7073037.

[6] S. F. Gillani, S. M. Umar Saeed, M. A. Zain Ul Abid E Din, Z. Shabbir and F. Habib (2021), "Prediction of Perceived Stress Scores Using Low-Channel Electroencephalography Headband," *International Bhurban Conference on Applied Sciences and Technologies (IBCAST)*, Islamabad, Pakistan, pp. 401-406, doi: 10.1109/IBCAST51254.2021.9393175.

[7] D'monte, G. Tuscano, L. Raut and S. Sherkhane (2018), "Rule generation and prediction of Anxiety Disorder using Logistic Model Trees," *International Conference on Smart City and Emerging Technology (ICSCET)*, Mumbai, India, pp. 1-4, doi: 10.1109/ICSCET.2018.8537258.

[8] AS Maria, R. Sunder y AM Antony (2023), "Predicción del estrés mediante la selección mejorada de funciones y el modelo KNN", *Tecnologías avanzadas de computación y comunicación para aplicaciones de alto rendimiento (ACCTHPA)*, Ernakulam, India, págs. 1 a 5, doi: 10.1109/ACCTHPA57160.2023.10083348.

[9] M. Mirbagheri, A. Jodeiri, N. Hakimi, V. Zakeri y SK Setarehdan (2019), "Evaluación precisa del estrés basada en la espectroscopia de infrarrojo cercano funcional usando un enfoque de aprendizaje profundo", 26.<sup>a</sup> Conferencia nacional y 4.<sup>a</sup> internacional iraní sobre ingeniería biomédica (ICBME), Teherán, Irán, págs. 4-10, doi: 10.1109/ICBME4916 *3.2019.9030394*.

[10] Attie Leah Beah Bella, Grinberg Jacobo (2010), "El potencial transferido", evidencia científicas de la comunicación directa entre cerebros. Laboratorio de Comunicación Humana de la facultad de Psicología de la UNAM.

[11] Renuka Suryawanshi, Sandeep Vanjale (2023),"Brain Activity Monitoring for Stress Analysis Through EEG Dataset using Machine Learning", International Journal of INTELLIGENT SYSTEMS AND APPLICATIONS INENGINEERIN, págs. 1-5.

[12] Claudia Nureibis Henríquez Muñoz (2014), "Estudio de Técnicas de análisis y clasificación de señales EEG en el contexto de Sistemas BCI (Brain Computer Interface)", Master Universitario en Investigacion e Innovación en TIC Universidad Autónoma de Madrid Escuela Politécnica Superior, págs. 9-14.

[13] Jorge Antonio Gaxiola Tirado (2016), "Clasificación de señales electroencefalográficas usando la coherencia parcialmente dirigida", Centro de Investigación y de Estudios Avanzados del Instituto Politecnico Nacional Unidad Monterrey, págs. 4-8.

[14] Emotiv insight 5 canales. (s.f.). Sistema emotiv. https://www.emotiv.com/insight/#

[15] Emotiv launcher. (s.f.). Software emotiv. https://www.emotiv.com/emotiv-launcher/

[16] Emotiv. (s.f.). Basics of Neural Oscillations. https://www.emotiv.com/tutorials/basics-of-neural oscillations/

[17] Alejandro J. Orozco-Naranjo, Pablo A. Muñoz Gutiérrez (2013), "Detection of Pathological and Normal Heartbeat Using Wavelet Packet, Support Vector Machines and Multilayer Perceptron", Universidad del Quindío, Armenia-Colombia, págs. 1-2.

[18] María Josefa García Ortiz Miriam Maité Torres Núñez, Alejandro Torres Fortuny, Tania Roig Álvarez, Francisca Cruz Sánchez (2021), "High frequency audiometry in adolescents exposed to noises", Revista Cubana de Pediatría, Rev Cubana Pediatr vol.93 no.1 Ciudad de la Habana ene.-mar.

[19] Jesús Fernández. (14 de agosto de 2014). F. Chopin, Nocturne en do sostenido menor para violín y piano <u>Nocturno nº 20 en Do# menor Frédéric</u> <u>Chopin - Deviolines</u>. https://www.deviolines.com/nocturno-no-20-en-do-menor-frederic-chopin/

[20] Richa Gupta, M. Afshar Alam, and Parul Agarwal (2020) "Modified Support Vector Machine for Detecting Stress Level Using EEG Signals", Hindawi Computational Intelligence and Neuroscience volume 2020, Article ID 8860841, 14 pages, doi: 10.1155/2020/886084.

[21] Luis Enrique Mendoza (2020), "Procesamiento de datos discretos en 1D y 2D: Fourier, Coseno y Wavelet", Universidad de Pamplona Colombia, Universidad de Pamplona Facultad de Ingenierías y Arquitectura Ingeniería en Telecomunicaciones, Ingeniería Electrónica e Ingeniería Industrial Colombia. [22] Brij N. Singh, Arvind K. Tiwari (2006), "Optimal selection of wavelet basis function applied to ECG signal denoising" National Polytechnic Institute ScienceDirect, volume 16, Issue 3, May, Pages 275-287.

[23] Mathworks. (s.f.). Documentation. Visualize and assess classifier performance in classification learner.

https://la.mathworks.com/help/stats/assess-classifier performance.html

[24] Xaviersz. (2024). Heracles666/allDataset. https://github.com/Heracles666/allDataSet

[25] Emotiv. (2024). Observar como se desarrolla la actividad cerebral. [imagen].

https://www.emotiv.com/products/emotivpro

[26] Ji. SY., Jayarathna, S., Perrotti, AM, Kardiasmenos, K., Jeong, DH. (2023), "EEG Analysis of Neurodevelopmental Disorders by Integrating Wavelet Transform and Visual Analysis", En: Shaban-Nejad, A., Michalowski, M., Bianco, S. (eds) Inteligencia artificial para la medicina personalizada. W3PHAI 2023. Estudios en Inteligencia Computacional, vol 1106. Springer, Cham. doi: 10.1007/978-3-031-36938-4\_9.

[27] Kumar, S., Forster, H. M., Bailey, P., & Griffiths, T. D. (2008), "Mapping unpleasantness of sounds to their auditory representation", *The* Journal of the Acoustical Society of America, 124(6), 3810-3817.

[28] Kumar, S., von Kriegstein, K., Friston, K., & Griffiths, T. D. (2012), "Features versus feelings: dissociable representations of the acoustic features and valence of aversive sounds", Journal of Neuroscience, 32(41), 14184-14192.

[29] Thiebaut, G., Méot, A., Prokop, P. et al. (2024) "Why are we Afraid of Holes? A Brief Review of Trypophobia Through an Adaptationist Lens", Evolutionary Psychological Science 10, 269–281, doi: 10.1007/s40806-024-00396-1.

[30] Clemente, D., Davì, L. & De Monte, E. (2020) "Use of Digital Stimulation in the Treatment of Phobias: Results Following EEG and Evoked Potential", J. technol. behav. sci. 5, 40–46, doi: 10.1007/s41347-019-00111-z.

[31] Escurra Mayaute, L. M., & Delgado Vásquez, A. E. (2010). "Análisis psicométrico del Test de Matrices Progresivas Avanzadas de Raven mediante el Modelo de Tres Parámetros de la Teoría de la Respuesta al Ítem". Persona, Universidad de Lima Perú (13), 71-97.

[32] Ziaratnia, S., Sripian, P., Laohakangvalvit, T., Sugaya, M. (2023). "Comparación de las respuestas fisiológicas a la prueba de color de palabras de Stroop y la estimulación IAPS." En: Duffy, VG (eds) Modelado humano digital y aplicaciones en salud, seguridad, ergonomía y gestión de riesgos. HCII 2023. Apuntes de conferencias sobre informática, vol 14029. Springer, Cham. doi: 10.1007/978-3-031-35748-0\_15.

[33] Castillo Pérez, B. E. (2021). "Rasgos de la personalidad en la atención selectiva en los estudiantes de la carrera de Psicología Educativa en la Universidad Nacional de Chimborazo" (Bachelor's thesis, Riobamba).