

**DETECCION TEMPRANA DEL SUEÑO A PARTIR DEL COMPORTAMIENTO DE LOS  
OJOS Y BOCA**

**Carlos arturo torres varon**

**Trabajo Dirigido**

**Tutor  
Ing. Oscar Julián Perdomo Charry**



**UNIVERSIDAD DEL ROSARIO  
ESCUELA COLOMBIANA DE INGENIERÍA JULIO GARAVITO  
PROGRAMA DE INGENIERÍA BIOMÉDICA  
BOGOTÁ D.C  
2022**

## **AGRADECIMIENTOS**

Agradezco a mis padres por su apoyo incondicional durante todo el trayecto de mi carrera, a mis hermanas por siempre estar a mi lado y aconsejarme en los momentos difíciles, gracias a mis amigos en especial a Julián Calvo, que me acompañó y ayudó a crecer como persona y como estudiante además de siempre creer en mí.

Le doy gracias al Ingeniero Oscar Julián Perdomo Charry, por acompañarme y guiarme durante este proyecto.

Por último le doy gracias a mi tía y mi primo por hacer parte de este recorrido.

## TABLA DE CONTENIDO

1. INTRODUCCIÓN.....	5
2. OBJETIVOS .....	6
2.1. General.....	6
2.2. Específicos .....	6
3. ESTADO DEL ARTE .....	7
3.1. Aprendizaje automático o Maquina de aprendizaje.....	7
3.1.1. Aprendizaje Supervisado .....	7
3.1.2. Aprendizaje No Supervisado .....	7
3.1.3. Aprendizaje por refuerzo .....	7
3.1.4. Aplicaciones de ML en salud .....	7
3.1.5. Lógica Difusa.....	8
3.2. Detección automática de rostro .....	9
3.3. Algoritmos para la detección automática de somnolencia.....	10
3.4. Base de datos de somnolencia .....	11
4. METODOLOGÍA.....	13
4.1 Elección de variables detectables en el rostro .....	13
4.2 Detección del rostro en tiempo real y cálculo de variables.....	13
4.3 Generación de variables y funciones de membresía de la lógica difusa .....	15
5. RESULTADOS .....	18
5.1 Captura del rostro y ubicación de puntos de referencia .....	18
5.2 Calculo del PERCLOS y grado de apertura de la boca.....	19
5.3 Reglas de la lógica difusa y resultados de predicción. ....	20
6. DISCUSIÓN.....	22
7. RECOMENDACIONES Y TRABAJOS FUTUROS.....	25
8. CONCLUSIONES .....	26
REFERENCIAS .....	27
ANEXOS.....	30

## Lista de Figuras

Figure 1	Imágenes de los sujetos de la base de datos DROZY .....	12
Figure 2	Malla facial obtenida de Face Mesh. A: Malla facial completa, B: Malla con zoom del ojo, C: Malla con zoom de la boca .....	14
Figure 3	En esta imagen se puede apreciar los puntos de referencia marcados en el ojo y en la boca para el cálculo de PERCLOS y el grado de apertura de la boca. ....	15
Figure 4	Grafica de las funciones de membrecía y las variables del universo de discurso pertenecientes al grado de apertura de la boca. ....	16
Figure 5	Grafica de las funciones de membrecía y las variables del universo de discurso pertenecientes porcentaje de apertura de los ojos. ....	16
Figure 6	Grafica de las funciones de membrecía y las variables del universo de discurso pertenecientes al indicador de bostezo. ....	16
Figure 7	Grafica de las funciones de membrecía y las variables del universo de discurso pertenecientes al indicador de los ojos. ....	17
Figure 8	Grafica de las funciones de membrecía y las variables del universo de discurso pertenecientes a la clase de salida. ....	17
Figure 9	Malla facial resaltando ojos, labios y el contorno del rostro .....	18
Figure 10	lustración de marcadores sobre diferentes personas .....	18
Figure 11	Marcadores en los labios marcando los puntos de referencia para la medición del grado de apertura de la boca .....	19
Figure 12	Representación gráfica del PERCLOS por tiempo transcurrido un numero de muestras tomada. Los valores por debajo de 0.8 indican el inicio del parpadeo .....	19
Figure 13	Representación gráfica del bostezo por tiempo transcurrido un numero de muestras tomadas .....	20
Figure 14	Imagen de cada sujeto junto con la matriz confusión generada por predicción de somnolencia de cada persona. ....	20
Figure 15	Grafica de predicción de la somnolencia.....	21
Figure 16	Graficas de grado de apertura de la boca, PERCLOS y valores de detección del sueño.....	23

## Lista de Tablas

Table 1	Datos estadísticos de cada uno de los sujetos. No sueños clase 0, Sueño clase 1. ....	21
---------	---	----

## 1. INTRODUCCIÓN

En Colombia la tasa de fallecimiento por accidentes de tránsito es de 14 por cada 100.000 habitantes, de estos el 45% de los accidentes se debe por estados de fatiga [1]. La fatiga es una pérdida progresiva de la capacidad de respuesta ante una situación, los efectos del cansancio a la hora de conducir pueden ser la reducción de la vigilancia, tiempos de reacción más lentos, micro sueños y disminución de reflejos [2]. Los micro sueños son sueños rápidos de no más de 5 segundos, en lo que el conductor va a 100Km/h puede llegar a recorrer alrededor de 130m sin estar consiente, es por esta razón que autos de gama alta cuentan con sensores que interpretan si el conductor está cansado por medio de cámara infrarrojas que pueden realizar el seguimiento de los ojos para determinar si se está concentrado o no y tomar medidas antes tal situación, también son capaces de determinar el cansancio por medio del comportamiento al manejar como por ejemplo salirse del carril entre otras.

Los métodos de detección del cansancio se clasifican en tres grupos; el primer grupo consiste en el estudio del comportamiento vehicular usando en gran medida sensores en el auto y volante. El segundo grupo detecta el cansancio de forma conductual, usando el procesamiento de imágenes y videos captados por cámara. El último grupo se basa en el estudio fisiológico, este método es intrusivo ya que el conductor debe estar usando sensores en diferentes partes del cuerpo en todo momento [3].

El enfoque conductual como se mencionó, se centra en la detección de la fatiga por medio de imágenes capturadas del conductor con ayuda de cámaras, en estas imágenes se busca analizar características como los son los ojos, boca, postura de la cabeza, porcentaje de cierre de los ojos (PERC-LOS), rostro, parpadeo, cierre de los ojos. Dichos datos se analizan con programas para determinar el estado del conductor [3].

Trabajos como el de [4] se basaron en el enfoque conductual para realizar un algoritmo de detección de somnolencia usando AdaBoost como clasificador para detectar la cara y evaluar el estado de los ojos, el estudio se realizó con una cámara infrarroja con la que obtuvieron precisión del 95% teniendo en cuenta PERC-LOS del 10%. Otro trabajo basado en la conducta, uso la tasa de parpadeos de los ojos con una tasa de precisión del 94% con una cámara web [5]. En [6] determinan el estado del conductor haciendo seguimiento de la cabeza y la zona de mirada, para este trabajo se utilizó un modelo pre entrenado de MT-Mobienest el cual reconocía comportamientos faciales varios, con el método utilizado lograron una precisión del 90.50%.

Este proyecto busca determinar la fatiga del conductor usando el enfoque conductual, teniendo en cuenta las diferentes variables mencionadas que se presentan durante el cansancio. El algoritmo se planteará a partir de machine learning y los datos se obtendrán adaptando la herramienta MediaPipe la cual permite la captación y parametrización de facciones de la cara y su seguimiento.

## **2. OBJETIVOS**

### **2.1. General**

Detectar y alertar de forma temprana el cansancio del conductor analizando video en tiempo real.

### **2.2. Específicos**

- a) Detectar y alertar de forma temprana el cansancio del conductor analizando video en tiempo real.
- b) Implementar un algoritmo de detección automática de cansancio a través de videos capturados con dispositivos de bajo costo.
- c) Generar elementos de retroalimentación visuales y auditivas para alertar tempranamente a los conductores.

### 3. ESTADO DEL ARTE

#### 3.1. Aprendizaje automático o Maquina de aprendizaje

El aprendizaje automático o en ingles Machine Learnig (ML), se conoce como una serie de algoritmos que hacen que un sistema sea inteligente artificialmente, se considera este como una rama de la inteligencia artificial. El aprendizaje automático se puede categorizar de dos maneras, aprendizaje supervisado y aprendizaje sin supervisión.

##### 3.1.1. Aprendizaje Supervisado

Aquí nosotros guiamos al algoritmo para que este llegue a la respuesta correcta, usando un conjunto de datos clasificados bajo cierta apreciación para encontrar patrones que se pueda usar en un análisis y así producir una salida que ya se conoce. Dentro los algoritmos más utilizados están: *linear regression, logistic regression, support vector machines, bayesian classifiers, Deep learning* entre otras más [7].

##### 3.1.2. Aprendizaje No Supervisado

Es un modelo predictivo que se entrena de manera similar al aprendizaje supervisado, con la diferencia en que los datos no están clasificados y el modelo encuentra patrones entre grupos de datos para realizar la predicción. Algunos de los algoritmos más usados son: *clustering K-means, principal componet analysis y anomaly detection* [7].

##### 3.1.3. Aprendizaje por refuerzo

En este modelo de aprendizaje no contamos con una etiqueta de salida, por lo que este tipo de algoritmos aprenden por sí mismos. El aprendizaje por refuerzo intentara hacer aprender a la maquina con premios y castigos en un entorno en el que tenga que tomar decisiones y este afectado por diferentes variables que van cambiando [7].

##### 3.1.4. Aplicaciones de ML en salud

Como se sabe, el ML resuelve situaciones por si solo a partir del análisis de datos, es por eso que tiene aplicación es múltiples áreas, como por ejemplo aplicaciones de uso cotidiano como redes sociales, correos electrónicos, detección de patrones de imágenes, etc.

Aparte del uso en aplicaciones de ocio, podemos encontrar modelos predictivos para el estudio de enfermedades y softwares para el diagnóstico de enfermedades en diferentes campos de la medicina.

Se han visto modelos de aprendizaje para el diagnóstico de cáncer de mama que es una de las causas más importantes de muerte entre las mujeres y su detección temprana acompañado de un tratamiento rápido puede reducir el riesgo de muerte. En [8] trabajan con técnicas basadas en redes neuronales artificiales para el diagnóstico

de cáncer de mama y un sistema basado en computación en la nube para el diagnóstico remoto, estas técnicas tuvieron resultados experimentales positivas con precisión del 98.68%.

Otros estudios han implementado algoritmos semisupervisados como en [9] que implementan un método computacional denominado KR-NSSM para seleccionar muestras negativas confiables para las predicción de asociación de miRNA-disease, la predicción de este trabajo se hace con el fin de proporcionar muestras negativas más confiables ya que en estudios biomédicos han demostrado que la difusión de miRNA esta relaciona con muchas enfermedades, y la identificación de estas contribuirían a la comprensión de los mecanismos patológicos de las enfermedades.

Los algoritmos de aprendizaje pueden usar en el diseño de prótesis biónicas con el fin de ayudar a discapacitados que les falten extremidades. Por medio de la adquisición de señales de EMG, se proponen algoritmos de clasificación supervisados para identificar patrones de agarre de las señales EMG y de esta forma aumentar la tasa de reconocimiento, este método algoritmos de regresión supervisado puedes predecir el movimiento y fuerza [10]. Otros métodos aplicados en este campo, se realizan redes de predicción neuronal profunda que aplican una estructura convolucional unidimensional para aprender automáticamente las características complejas de señales EMG [11].

En cuanto a señales de EEG, existen modelos que aplican las señales obtenidas para el diagnóstico de enfermedades mentales usando regresión logística [12] o con las mismas señale se usan para la activación de exoesqueletos para extremidades inferiores [13]. La espectroscopia de infrarrojo cercano funcional se puede usar junto con redes neuronales covolucionales basadas en aprendizaje profundo para la clasificación de diferentes estados cognitivos como tareas mentales o estados de reposo [14]. Aparte de la aplicaciones de diagnóstico de enfermedades, el ML se puede usar en el análisis de conglomerados de datos como el caso de [15] o determinar la incidencia de alguna enfermedad en comunidades [16] [17].

### 3.1.5. Lógica Difusa

La lógica difusa es una de las técnicas usadas en ML basada en el aprendizaje no supervisado. A diferencia de la lógica ordinaria, que toma solo dos valores de verdad, 0 y 1, la lógica difusa puede tomar valores de verdad parciales entre 0 y 1 de forma aleatoria, pero contextualizada y referidas entre sí, por ejemplo, una persona que mide 2 metros es claramente alta si antes se ha tomado el valor de una persona baja de 1 metro, por lo que los valores están contextualizado y referidos en una medida métrica lineal. Esta técnica que basa en reglas, se necesita de la participación humana para la creación de dichas reglas que evalúan cada muestra para la coincidencia optimas de los valores durante la clasificación [18].

Para aplicar la lógica difusa se deben seguir una serie de pasos, lo primero consiste en dar las características de entrada al sistema difuso, luego de esto, las entradas se difuminan y se crean funciones de membresía. Después de eso, se establecen las reglas difusas y sobres estas reglas, las salidas difusas se generan mediante la multiplicación lógica. A



continuación, se lleva a cabo la defuzzificación de las salidas y se obtiene la salida final [19].

La lógica difusa ha tomado gran impulso por su variedad de aplicaciones que van desde el control de procesos industriales hasta el diseño de dispositivos para la deducción automática, artefactos de uso doméstico, como tomo también sistemas de diagnóstico. En cuanto a su uso en el área médica, se han realizado programas para el diagnóstico de enfermedades, por ejemplo, en la detección de convulsiones, un equipo de trabajo propuso un modelo de clasificación de EEG basado en un clasificador de lógica difusa auto organizada (SOF) para la detección de convulsiones en pacientes cruzados y específicos, en el que la media general alcanza el 92.04% de acierto [20].

El reconocimiento de emociones, es uno de los campos donde se han aplicado diferentes algoritmos de ML, a este se suma también la lógica difusa, en [21] plantean un sistema que se compone en dos etapas donde una se encarga del procesamiento de imágenes y la otra del reconocimiento de emociones, en la etapa de reconocimiento de emociones identifican puntos en el rostro para confundir determinar la fuerza de diferentes acciones faciales, en función de estas fortalezas se determinaron las emociones, el sistema planteado tuvo un rendimiento del 78,8%.

La lógica difusa también se ha aplicado en el análisis de señales de electrocardiograma y detectar anomalías cardiacas. Trabajos como el de [22] y [23] usan un sistema neurodifuso basado en funciones de pertenencia difusas ponderadas para el diagnóstico de enfermedades del corazón, la precisión del método de clasificación se probó con 48 registros de la base de datos MIT-BIH que mostro una clasificación exitosa del 100% de precisión [24].

### **3.2. Detección automática de rostro**

MediaPipe es una herramienta desarrollada por Google la cual cuenta con diferentes soluciones como la detección del rostro, detección y seguimiento de poses humanas, seguimiento de manos entre otras. Esta aplicación es de código libre se puede implementar en diferentes plataformas como teléfonos Android/IOS, PC, y la nube. Se puede utilizar como librería en lenguajes de programación como Python o JavaScript [25].

Con el uso de esta herramienta se han desarrollado varias ideas enfocadas en ámbito de la ingeniería biomédica, como por ejemplo la aplicación Mirru que puede controlar manos protésicas mediante el seguimiento de manos, lo que permite al usuario duplicar al instante movimientos como agarres de su mano sana en una robótica, esta idea brinda una alternativa económica, intuitiva y de fácil acceso [26]. Una aplicación similar a la mencionada anteriormente es SingAll SDK, que es una interfaz de lenguaje de señas, con esta tecnología se puede lograr que el lenguaje de señal este universalmente disponible, tanto en la comunicación entre sordos y oyentes como entre personas sordas y computadoras [27].

Face Mesh es una de las herramientas computacionales que se usaran en este proyecto. Esta librería permite la detección de rostros y estima puntos de referencia faciales en 3D

en tiempo real, el proceso se realiza mediante aprendizaje automático lo que logra que se pueda usar esta aplicación sin la necesidad de cámaras con sensores de profundidad.

El proceso que sigue Face Mesh inicia tomando todo el fotograma de entrada de la cámara y se procesa en un detector de rostros (MediaPipe Face Detection [28]), el cual delimita el rostro con rectángulos en las caras que te detecte y algunos puntos de referencia como ojos y boca. La imagen procesada del detector de rostros, pasa a ser la entrada de la red neuronal que forma la malla, este modelo produce un vector de coordenadas con puntos de referencia en 3D. Para obtener todos los 468 puntos de referencia de la malla facial, se entrena un modelo inicial usando dos fuentes de supervisión, una son representaciones sintéticas de un 3DMM (3D movie maker) sobre los rectángulos faciales obtenidos de imágenes de rostros reales, en el que se ubican de forma inmediata los 468 puntos de referencia de manera predefinida. El segundo son puntos de referencia 2D correspondientes a los vértices en la malla, que están presentes en un conjunto de contornos semánticos. Luego de entrenar el modelo, los datos fueron refinados iterativamente en ejes coordenados de X y Y. El resultado son mallas que representa texturas 3D realistas que se alinean sobre la cara, aunque no llegan a ser métricamente precisas [29].

### **3.3. Algoritmos para la detección automática de somnolencia**

La detección de somnolencia tiene gran importancia en cuanto aplicaciones de seguridad en los conductores, ya que al día de hoy los vehículos de gama baja y media no cuentan con sistemas de monitorización que pueden tomar el mando del automóvil en caso del que el conductor tenga un micro sueño o este distraído.

Se han realizado diferentes métodos para la detección del sueño registrando parámetros visuales en el rostro de una persona, con el fin de introducir tecnologías no invasivas para monitorizar de forma constante el estado del conductor. El seguimiento ocular captado por cámaras, ayuda a identificar la fatiga presente en una persona, en [30] se investigó un método de evaluación para determinar el estado fatiga en pilotos, con ayuda de un seguidor ocular (iView X RED, SMI company, Germany) realizaron pruebas en voluntarios, en las que tenían que realizar una serie de tareas en una simulación de vuelo de 10 minutos, durante el ejercicio registraron la frecuencia de parpadeo y el porcentaje de apertura de los ojos (PERCLOS), el proceso se realizó en tanto en el día como en la noche y con ayuda de un encuesta realizada a los participantes, se pudo concluir que en el estado de fatiga la frecuencia de parpadeo aumenta, y el tiempo de cierre de los ojos durante el parpadeo aumenta, en cuanto al PERCLOS se detectó que este permanece bajo que coincide con el tiempo de parpadeo prolongado durante el estado de cansancio.

Con la ayuda del PERCLOS, y otros parámetros asociados a la fatiga como las actitudes y estrategias cognitivas sociales (AECS), se pueden usar técnicas holísticas como los ASM (Active shape models [31]) y con ayuda de modelos paramétricos se puede estimar la forma de un objeto con gran precisión, es de esta manera, que determinan el grado de cierre de los ojos y el grado de apertura de la boca para identificar la fatiga [32].

En los vehículos de gama alta, se encuentran sensores integrados en los volantes que miden sus movimientos, como el ángulo, la velocidad angular, la velocidad del volante, la posición de las manos entre otras más. Estos datos junto con métodos de aprendizaje automático logran crear modelos de monitoreo de somnolencia, en [33] usan los datos recopilados del volante en un entorno de simulación con modelos logit ordenado multinivel, modelos de máquinas de vectores y redes neuronales para el reconocimiento de somnolencia con acierto del 73%. Usando árboles de decisión con los datos del ángulo del volante y la entropía aproximada de este, detectan la fatiga del conductor con una precisión del 82% [34], con las mismas variables del ángulo del volante y la entropía aproximada [35], aplican un clasificador binario con el que obtienen un 78% de acierto a la hora de detectar la somnolencia.

A partir de mediciones fisiológicas también es posible determinar el estado de somnolencia, y aunque estos métodos resultan ser muy precisos, no son tan populares para el monitoreo de fatiga, ya que los instrumentos para obtener los diferentes parámetros fisiológicos son invasivos y resultan incómodos para los conductores. Usando un sistema de máquina de vectores y la integración de ECG y EEG [36] obtienen un modelo con un rendimiento del 80.90% destacando que el hecho que la combinación de señales fisiológicas de un mejor resultado que usándolas por separado. Un modelo que usó también un sistema de máquina de vectores logró hasta el 98.3% de acierto, con el uso de 5 variables fisiológicas [37].

### **3.4. Base de datos de somnolencia**

El conjunto de datos de detección de somnolencia del conductor recopilados por el laboratorio de visión por computadora de NTHU, cuenta con 36 sujetos de diferentes etnias con y sin anteojos de sol en una variedad de escenarios de conducción simulados, los sujetos fueron grabados mientras estaban en una silla frente a un juego de conducción con volante y pedales simulados. El tiempo total de todo el conjunto de datos es de unas 9 horas y media [38].

La base de datos proporcionada por [39] cuenta con 35 sujetos jóvenes, 21 mujeres y 14 hombres con edades de 23 a 27 años, los sujetos fueron privados del sueño por un periodo de 30 horas mientras realizaban diferentes actividades.

DROZY (The ULg Multimodality Drowsiness Database) es la base de datos que se usó en este proyecto como base para determinar estados de somnolencia en diferentes personas. La base de datos contiene varios tipos de datos relacionados con la somnolencia, fueron recopilados por el laboratorio de explotación de señales e imágenes (INTELSIG), que forma parte del departamento de ingeniería eléctrica y ciencias de la computación de la universidad de Liège (ULg), Liège, Bélgica, también denotado como ULg-INTELSIG.



Figure 1 Imágenes de los sujetos de la base de datos DROZY

## 4. METODOLOGÍA

Un microsueño es un episodio de sueño que puede durar entre 2 y 30 segundos, durante ese lapso de tiempo la persona no percibe estímulos externos. En caso de que una persona esté realizando tareas que requieran de su total concentración, un microsueño puede desencadenar consecuencias graves e incluso fatales [40]. Se cree que conducir bajo el estado de somnolencia es responsable de 1.2 millones de colisiones, 8000 muertes y 500000 lesiones cada año [41]. Es por esto que se ha vuelto necesario la implementación de métodos de detección de somnolencia por algunos de los métodos que se han mencionado previamente.

### 4.1 Elección de variables detectables en el rostro

Para empezar, se realizó una búsqueda de parámetros para identificar el estado de somnolencia, una persona en este estado presenta varias características faciales y movimientos como, cabeceos, bostezos frecuentes, parpadeos donde el tiempo en que se cierra y abre el ojo tarda más de que un parpadeo normal, el porcentaje de apertura de los ojos disminuye en otras. Se eligieron tres de estos parámetros para la detección de sueño, que son el porcentaje de apertura de los ojos (PERCLOS), el parpadeo lento y los bostezos, donde el más relevante es el PERCLOS ya que en la investigación de otros trabajos este indicio es de los más precisos para medir el cansancio en una persona.

El PERCLOS, indica que tan abierto se encuentra el ojo, en condiciones normales el porcentaje de apertura debe estar por encima del 80%, si el porcentaje se encuentra por debajo de este valor es un indicador de cansancio. Mediante el valor de PERCLOS, se puede evidenciar el parpadeo de una persona, y de la misma forma la duración del parpadeo que no debe superar los 200ms.

### 4.2 Detección del rostro en tiempo real y cálculo de variables

El algoritmo a realizar se hará con el lenguaje Python, el cual permite el uso de diferentes librerías que se verán más adelante. Una de estas librerías permite el reconocimiento facial con el que se podremos obtener los valores de cada una de las variables.

Con la librería Face Mesh, que hace parte de MediaPipe se realizará la detección del rostro y al mismo tiempo aplica una malla con diferentes puntos de referencia. En la Figura 1 se ve la malla que se aplica al rostro detectado.

De la figura 1B, se toman los puntos de referencia que se encuentran en el medio (145-159) y uno de la pupila. Para tomar el valor de la ubicación de los puntos, se debe tomar la posición relativa de X y Y que se obtiene de la posición del marcador en la malla multiplicado por la posición del punto de referencia en el rostro capturado.

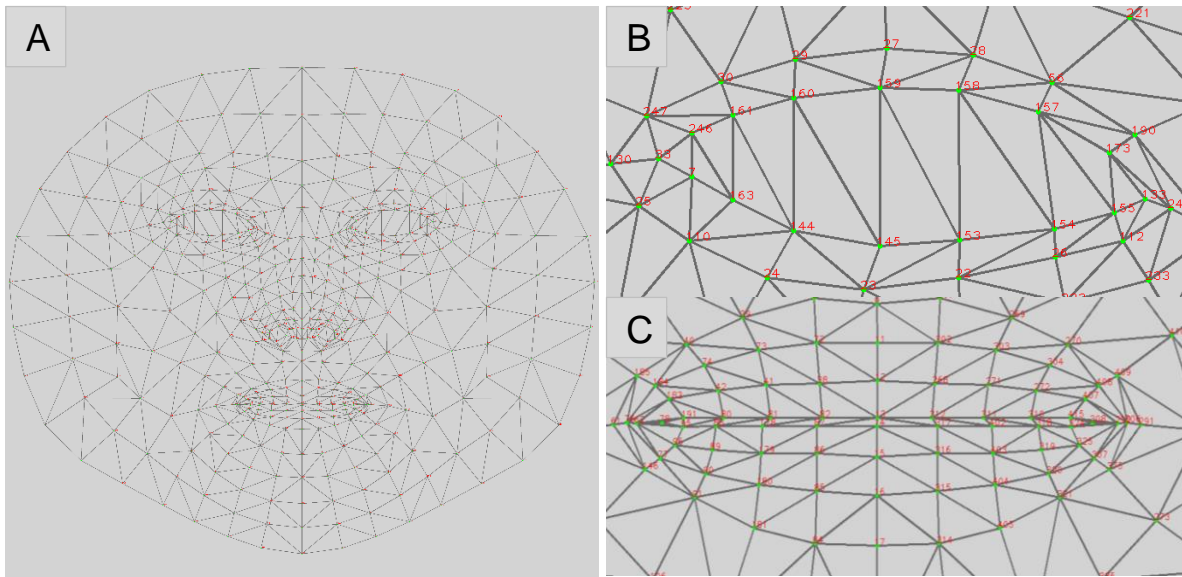


Figure 2 Malla facial obtenida de Face Mesh. A: Malla facial completa, B: Malla con zoom del ojo, C: Malla con zoom de la boca

Con estos puntos ubicados y marcados, calculamos la distancia que hay en entre ellos para sacar el porcentaje de apertura con la siguiente ecuación.

$$p = \frac{p_0}{pMax}$$

Dónde: p es el valor de PERCLOS obtenido,  $p_0$  es el valor que se obtiene de calcular la distancia entre puntos y pMax es el valor máximo que puede tomar los puntos, este último varía de acuerdo a la persona en un estado de no somnolencia.

El bostezo se toma a partir del grado de apertura de la boca cuyos valores varían del 0 al 1, cuando sea igual o mayor que 0.5 y su duración sea prolongada se toma como un bostezo. Se toman 4 puntos de referencia en la boca, dos ubicados en los vértices de la boca, uno en labio superior y el ultimo en el labio inferior, de igual forma, las coordenadas X y Y se obtienen a partir de la posición relativa de los marcadores. Con las coordenadas y usando la ecuación a continuación podemos calcular el grado de apertura de la boca.

$$bostezo = \frac{\text{distancia a lo ancho}}{\text{distancia a lo largo}}$$

La librería Opencv de Python permite la lectura tanto de imágenes como videos además de capturar video en tiempo real. Junto con face mesh, se tomará la imagen sobre la cual marcaremos los puntos de referencia mencionados anteriormente (figura 2).




Figure 3 En esta imagen se puede apreciar los puntos de referencia marcados en el ojo y en la boca para el cálculo de PERCLOS y el grado de apertura de la boca.

#### 4.3 Generación de variables y funciones de membresía de la lógica difusa

Con algunos de los videos de la base de datos DROZY, se realiza una tabla de datos, que contendrá los valores de PERCLOS, grado de apertura de la boca, y por otro lado dos indicadores, uno para determinar si se realizó un parpadeo largo, y otro para determinar si la persona bostezo. Esta tabla nos servirá como referencia en el siguiente paso.

La predicción del estado de somnolencia se realiza aplicando el método de ML lógica difusa. Se inicia generando las variables del universo de discurso:

- Grado de apertura de la boca con rango de 0 a 1 con incremento de 0.1
- PERCLOS con rango de 0 a 1 con incremento de 0.1
- Indicador de parpadeo largo con rango de 0 a 1 con incremento de 0.1
- Indicador de bostezo con rango de 0 a 1 con incremento de 0.1
- Clase con rango de 0 a 1 con incremento de 0.1

A continuación, se generan las funciones de membresía difusas, los rangos asignados a cada función se toman de la tabla realizada de los videos de la base de datos DROZY.

- Funciones pertenecientes al grado de apertura de la boca generadas con funciones sigmoides (figura 3):
  - Boca cerrada toma valores de 0 a 0.2
  - Boca cuando la persona está hablando toma valores de 0.3 a 0.49
  - Boca durante el bostezo toma valores de 0.5 a 1




Figure 4 Grafica de las funciones de membrecía y las variables del universo de discurso pertenecientes al grado de apertura de la boca.

- Funciones pertenecientes a el PERCLOS generadas con funciones trapezoidales (figura 4):
  - PERCLOS cansado toma valores de 0 a 0.80
  - PERCLOS normal toma valores de 0.6 a 1




Figure 5 Grafica de las funciones de membrecía y las variables del universo de discurso pertenecientes porcentaje de apertura de los ojos.

- Funciones pertenecientes a los indicadores de bostezo generadas con funciones trapezoidales (figura 5):
  - Indicador de bostezo negativo toma valores de 0 a 0.3
  - Indicador de bostezo positivo toma valores de 0.2 a 1




Figure 6 Grafica de las funciones de membrecía y las variables del universo de discurso pertenecientes al indicador de bostezo.

- Funciones pertenecientes a los indicadores los ojos generados con funciones trapezoidales (figura 6):
  - Indicador de ojos abiertos toma valores de 0 a 0.3



- Indicador de ojos cerrados toma valores de 0.2 a 1



Figure 7 Gráfica de las funciones de membresía y las variables del universo de discurso pertenecientes al indicador de los ojos.

- Funciones pertenecientes a la clase de salida generadas con funciones sigmoideas (figura 7).
  - Clase normal toma valores de 0 a 0.5
  - Clase cansado toma valores de 0.6 a 1




Figure 8 Gráfica de las funciones de membresía y las variables del universo de discurso pertenecientes a la clase de salida.

Finalmente, definimos las variables de antecedentes y consecuentes con las estableceremos las reglas a aplicar a nuestro simulador de sistema de control.

## 5. RESULTADOS

### 5.1 Captura del rostro y ubicación de puntos de referencia

Con ayuda de la detección automática de rostro, se capturo el rostro en los diferentes video e imágenes de la base de datos. En ellos se resalta las cejas, ojos, labios y el contorno de la cara como se ve en la captura de las imágenes en la figura 8, además nos brinda una malla de referencia sobre la cara del individuo.




Figure 9 Malla facial resaltando ojos, labios y el contorno del rostro

Teniendo en cuenta la información de la malla generada sobre la cara y los puntos marcados sobre la malla en la figura 1, se marcaron algunos puntos para realizar los cálculos pertinentes al PERCLOS y el grado de apertura de la boca. En la figura 9 se ven los marcadores sobre el parpado superior, el parpado inferior y la pupila.



Figure 10 Ilustración de marcadores sobre diferentes personas

Se ubicaron de igual forma marcadores sobre la boca. Los puntos marcados se colocaron en los vértices de la boca, en el labio superior y en el labio inferior como se ilustra en las imágenes de la figura 10.




Figure 11 Marcadores en los labios marcando los puntos de referencia para la medición del grado de apertura de la boca

## 5.2 Calculo del PERCLOS y grado de apertura de la boca.

El cálculo para el PERCLOS se realizó con la formula descrita en la metodología, se tomó como valor apertura normal del ojo los valores por encima de 0.8. Para visualizar los momentos en se realiza un parpadeo se realizó la gráfica presentada en la figura 11.

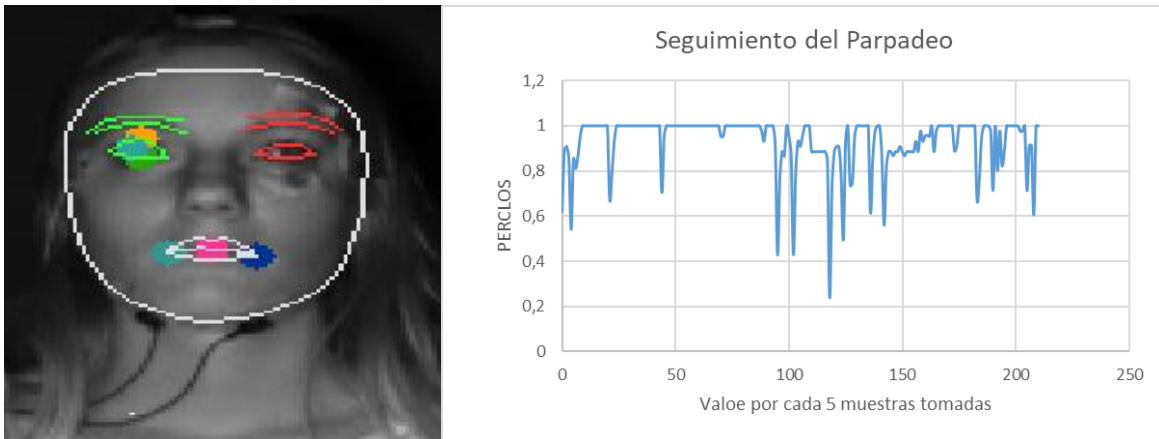


Figure 12 Representación gráfica del PERCLOS por tiempo transcurrido un numero de muestras tomada. Los valores por debajo de 0.8 indican el inicio del parpadeo

De igual forma el grado de apertura de la boca se realizó con la formula explicada en el apartado de metodología. Con el fin de comparar más adelante los resultados de la detección temprana del sueño, se graficaron los datos obtenidos del grado de apertura de la boca, donde los picos vistos en la figura 12 representan el bostezo de la persona.

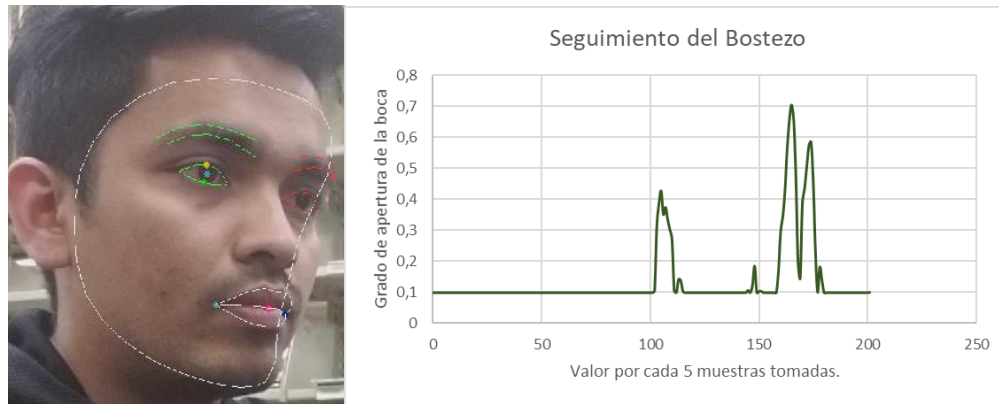


Figure 13 Representación gráfica del bostezo por tiempo transcurrido un numero de muestras tomadas

### 5.3 Reglas de la lógica difusa y resultados de predicción.

De forma inicial, se plantearon 20 reglas tratando de tener en cuenta diferentes situaciones en que se presentan los datos, después de algunas pruebas con diferentes sujetos de la base de datos, se terminaron usando solo 7 reglas (Reglas presentadas en los anexos) donde el PERCLOS tuvo más importancia a la hora de determinar el cansancio en una persona.

Con las 7 reglas establecidas, se evaluó el método de predicción en 4 sujetos de la base de datos. De los resultados generados se realizaron matrices de confusión para cada persona, y se tomaron algunas métricas para comparar.

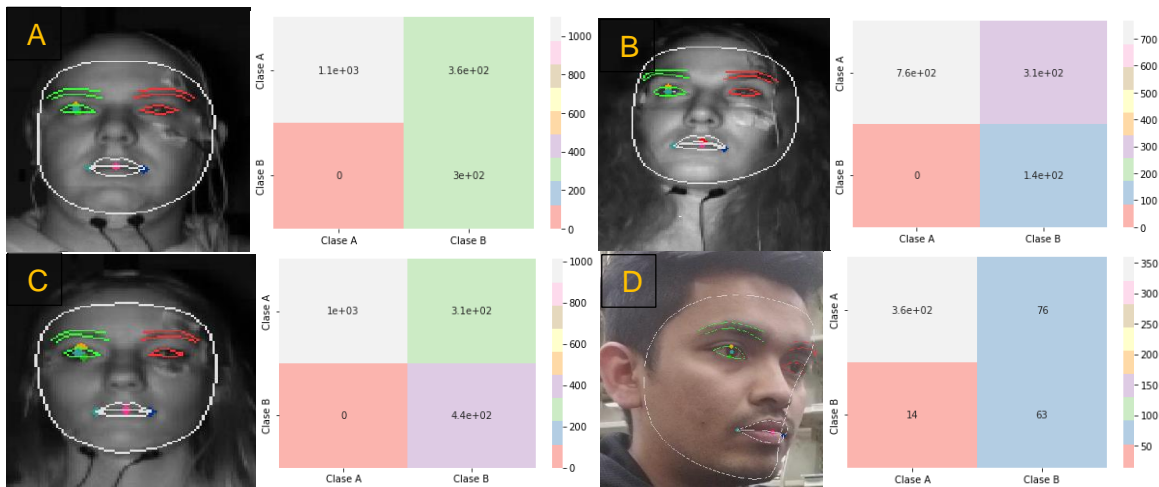


Figure 14 Imagen de cada sujeto junto con la matriz confusión generada por predicción de somnolencia de cada persona.

Las métricas que se usaron para evaluar el rendimiento del algoritmo de detección se presentan en la tabla 1, los datos se calcularon a partir de cada matriz de confusión.

Table 1 Datos estadísticos de cada uno de los sujetos. No sueños clase 0, Sueño clase 1.

	Sujeto A	Precision	Recall	F1-Score	Accuracy	Especificidad	Support
Clase	0	1	0,75	0,86	0,79	0,75	1462
	1	0,45	1	0,62			302
	Sujeto B	Precision	Recall	F1-Score	Accuracy		Support
Clase	0	1	0,71	0,83	0,74	0,71	1075
	1	0,3	1	0,47			135
	Sujeto C	Precision	Recall	F1-Score	Accuracy		Support
Clase	0	1	0,77	0,87	0,83	0,76	1318
	1	0,59	1	0,74			436
	Sujeto D	Precision	Recall	F1-Score	Accuracy		Support
Clase	0	0,96	0,83	0,89	0,82	0,82	435
	1	0,45	0,82	0,58			77

Como algo adicional se realizó una gráfica donde se puede ver la predicción de la lógica difusa, se muestra esta grafica ya que los valores usados en las métricas fueron estandarizados. La figura 14 permite la comparación con las figuras 11 y 12 de los momentos en que se supone ocurre la fatiga.




Figure 15 Grafica de predicción de la somnolencia

## 6. DISCUSIÓN

Al graficar los valores del PERCLOS, se vio que los valores por debajo de 0.8 indicaban el inicio de parpadeo de la persona, y en otras ocasiones la disminución de apertura de los ojos. En momentos de fatiga, se notaron valores de PERCLOS bajos, y la duración de los parpadeos eran más largos. Con ayuda de los puntos mostrados en la figura 9 se hizo seguimiento del comportamiento de los ojos, y con los valores obtenidos se realizó la gráfica de la figura 12, los picos hacia abajo representan el cierre de los ojos, en el caso de la persona mostrada en la misma figura podemos notar que con el paso del tiempo sus parpadeos aumentan debido al cansancio, en la gráfica evidencia por los picos largos y consecutivos, el cambio se hace evidente, ya que en el inicio de la gráfica podemos ver que ocurren parpadeos rápidos y distanciados. En algunos casos el valor de PERCLOS no llegó a ser cero, aunque el ojo estuviera totalmente cerrado por varios segundos, esto ocurre porque en la detección rostro, los vértices dibujados sobre los ojos no llegan a cerrarse, dejando siempre un pequeño espacio entre ellos a pesar de que esté cerrado el ojo.

Los picos de la figura 12, representan momentos en que la persona bostezaba, inicialmente el bostezo se tomó a partir de valores mayores o iguales 0.5, pero se notó que algunas personas no abren demasiado la boca para bostezar si no que hacen un esfuerzo para que permanezca cerrada, por esta razón disminuyó el valor de referencia de bostezo a 0.4. Un problema con estos valores, se da cuando un sujeto tapa su boca con su mano al bostezar, en este momento, las líneas que resaltan los labios y sus puntos de referencia, se superponen a la mano y toman la forma de estar completamente cerrados. Al ver este error para la toma de valores, la importancia del bostezo sobre la predicción de somnolencia disminuyó dando más peso al PERCLOS.

Respecto a la elaboración del algoritmo de detección automática de la somnolencia, se aplicó el método de lógica difusa. Al momento de generar las funciones de membresía de las diferentes variables consideradas en este proyecto, se vio que no todas las variables funcionaban con las mismas funciones, ya que, al momento de probar el algoritmo con diferentes reglas, la predicción resultó ser nada buena. Durante las pruebas realizadas, se decidió cambiar las funciones que, en un principio, eran todas de tipo trapezoidal a funciones sigmoideas en las variables del grado de apertura de la boca y la clase. Las funciones gaussianas, triangulares, por partes en otras, fueron probadas, pero obtuvieron no obtuvieron buenos resultados.

En un principio, se establecieron 20 reglas para usarlas en el simulador del sistema de control. Estas reglas, solo permitieron predecir momentos donde la persona no tenía somnolencia, en cuanto se presentaba fatiga, el indicador de clase no presentaba mayor cambio. El sistema de clasificación toma valores de 0 a 1, con las 20 reglas, si se presentaba indicios de sueño el máximo valor obtenido era de 0.3, que en comparación de momentos de no somnolencia los valores variaban entre 0.1 y 0.2. Se probó ir reduciendo la cantidad de reglas, hasta llegar a solo 7 que fue el punto donde mejores resultados se obtuvieron y con los que se siguió trabajando.

Se realizaron 4 matrices de confusión, con el fin de probar el algoritmo en diferentes sujetos. En las figuras 13A, 13B y 13C, son sujetos que presentaron microsueños, pero durante la toma no bostezaron. En la tabla 1 tenemos las métricas de nuestro sistema de detección, en los tres sujetos mencionados, la clase 1 tienen valores de precisión bajos, pero

sensibilidades muy altas, en los tres casos del 100%, en otras palabras, el sistema detecta bien las clases, pero incluye muestras de la otra clase, pero su especificidad llegar a ser en promedio del 74% que no es un porcentaje muy alto, pero no llega a ser malo, ya que, en nuestro caso, que es la aplicación para detectar el sueño, es difícil que el sistema obtenga falsos positivos.

El sujeto de la figura 13D, tiene métricas algo diferentes a la de los tres sujetos anteriores, tiene el porcentaje de exactitud más alto que es de 82%, y en cuanto las métricas en las dos clases, son más balanceadas, es decir, valores cercanos los unos de los otros, esto se debe a que la cantidad de datos que tiene es menor a comparación de los otros, por lo que sus métricas no pueden ser muy confiables del todo.

Un punto a mencionar, es que la base de datos obtenida no es simétrica, por tanto, algunas métricas como la exactitud no es tan acertada, para evaluar mejor la robustez del algoritmo tomaremos el puntaje F1, que en promedio es de 86%. Aunque el porcentaje no es el esperado se acerca bastante a la meta del 90% y a comparación de otros trabajos de detección de somnolencia a partir de rasgos faciales tiene un porcentaje más alto [42] [43].

Ya que, para poder tomar las métricas del algoritmo, se tuvo que normalizar los datos obtenidos para que fuera valores de 0 o 1, el rendimiento visualizado en las estadísticas se ve afectado, una forma en la que se evaluó el sistema fue mediante la comparación grafica del PERCLOS, el grado de apertura de la boca y la predicción del algoritmo figura 15.

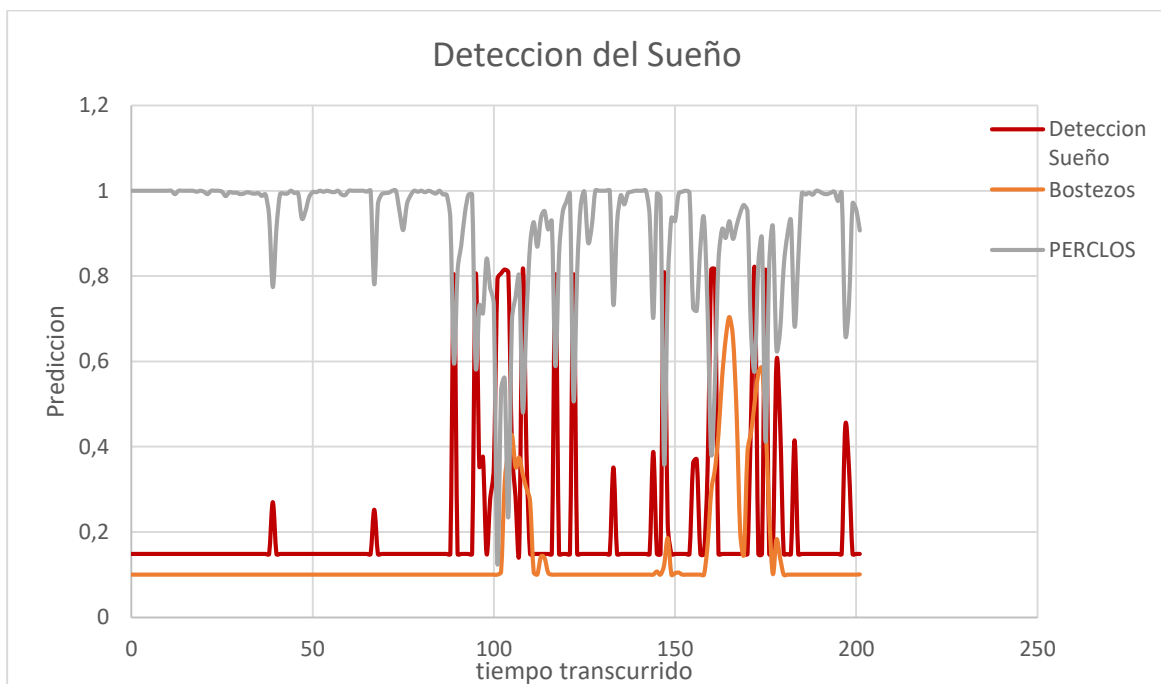


Figure 16 Gráficas de grado de apertura de la boca, PERCLOS y valores de detección del sueño.

Podemos detallar, que en los momentos donde el PERCLOS y los valores del grado de apertura son más grandes, los valores de la predicción aumentan, como se explicó antes,

el modelo toma valores entre 0 y 1, y entre más cerca este de 1 significa mayor riesgo de somnolencia. La ventaja de que tome diferentes valores es que a medida que la persona se torne más cansada el valor de predicción va aumentando, por tanto, el sistema permite la detección temprana de somnolencia.



## **7. RECOMENDACIONES Y TRABAJOS FUTUROS**

El software desarrollado en este trabajo, puede servir como referencia a otros estudios de detección temprana del sueño a partir de lógica difusa, además de que se puede comparar con otros modelos de aprendizaje automático.

A trabajos futuros el algoritmo se puede testear con una base de datos diferente y de clases simétricas para corroborar los datos de las matrices de confusión elaboradas en el proyecto. También se puede intentar implementar en pruebas de simulación de conducción para evaluar si eficiencia en un ambiente más real.

El sistema se puede complementar, aplicándolo a un dispositivo móvil, ya sea aplicándolo directamente al teléfono celular, apoyándose de la cámara que posee o bien sea implementando una cámara con sistemas de alarmar como una luz o un sonido, que se comunique con el teléfono.

## **8. CONCLUSIONES**

El algoritmo desarrollado en el proyecto, probó de manera eficiente la detección temprana del cansancio por medio de la detección del rostro tomando como referencia los ojos y la boca. En la figura 15 presentada en el apartado de discusión, se logró visualizar la relación entre el PERCLOS y el grado de apertura de la boca con el nivel de somnolencia en una persona. Con las matrices de confusión, el sistema demostró que clasifica bien los datos, con un buen índice de especificidad y sensibilidad en general.

Aunque los resultados del proyecto fueron netamente obtenidos de videos de bases de datos de somnolencia, se logró probar el sistema mediante una cámara web, en la que se hicieron diferentes gestos simulando el estar cansando y dando buenos resultados a la hora de predecir la somnolencia, lo que nos lleva a pensar que el algoritmo se puede implementar en dispositivos de bajo costo y emplearse en situaciones de la vida real. La finalidad de que el dispositivo sea de bajo costo, es que conductores de vehículos de gama media y baja, puedan acceder a este y usarlo a diario, sobre todo sería de utilidad a conductores que trabajan a altas horas de la noche o por largas jornadas de trabajo y de esta forma reducir el porcentaje de accidentes causada por micro sueños.

## REFERENCIAS

- [1] SURA, «arsura,» [En línea]. Available: [www.arlsura.com/index.php/component/content/article?id=1469](http://www.arlsura.com/index.php/component/content/article?id=1469). [Último acceso: 16 11 2022].
- [2] C. C. d. Seguridad, «CCS,» [En línea]. Available: <https://ccs.org.co/somnolencia-y-conduccion/>. [Último acceso: 16 11 2022].
- [3] J. C. N. K. F. F. V.E Machaca Arceda, «A Survey on Drowsiness Detection Techniques,» *CEUR-WS*, vol. 2747, nº 14.
- [4] B.-G. H. K.-J. K. Y.-S. C. S.-I. L. Jang Woon Baek, «Real-time drowsiness detection algorithm for driver state monitoring systems,» *in 2018 Tenth International Conference on Ubiquitous and Future Networks (ICUFN)*, pp. 73-75, 2018.
- [5] M. S. A. K. Amna Rahman, «Real Time Drowsiness Detection using Eye Blink,» *National Software Engineering Conference (NSEC 2015)*, pp. 1-7, 2015.
- [6] A. U. J. L. J. D. S. V. H. C. Khan Muhammad, «Deep Learning for Safe Autonomous Driving: Current Challenges and Future Directions,» *IEEE TRANSACTIONS ON INTELLIGENT TRANSPORTATION SYSTEMS*, pp. 4316-4336, 2021.
- [7] E. M. Rojas, «Machine Learning: análisis de lenguajes de,» *Revista Ibérica de Sistemas e Tecnologías de Información*, nº E28, pp. 586-599, 2020.
- [8] H. S. A. A. B. S. M. A. M. R. D. S. K. K. C. Vivek Lahoura, «Cloud Computing-Based Framework for Breast Cancer,» *Diagnostics*, vol. 11, p. 241, 2021.
- [9] H. C. W. W. G. W. F. L. Ruiyu Guo, «Predicting potential miRNA-disease associations based on more reliable negative sample selection,» *BMC Bioinformatics*, vol. 23, nº 432, 2022.
- [10] S. L. T. Y. J. A. Z. Z. X. L. Yansheng Wu, «Classification and simulation of process of linear change for grip force at different grip speeds by using supervised learning based on sEMG,» *Expert Systems with Applications*, vol. 206, 2022.
- [11] K. W. C. Jiaqi Xue, «Dynamic gripping force estimation and reconstruction in EMG-based human-machine interaction,» *Biomedical Signal Processing and Control*, vol. 80, nº 1746, 2022.
- [12] S.-W. Sunil Kumar Prabhakar, «Improved Sparse Representation based Robust Hybrid Feature Extraction Models with Transfer and Deep Learning for EEG Classification,» *Expert Systems with Applications*, vol. 198, nº 116783, 2022.
- [13] A. K. B. S. D. S. B. Ganesh Roy, «Cross-correlated spectral entropy-based classification of EEG motor imagery signal for triggering lower limb exoskeleton,» *Signal, Image and Video Processing*, vol. 16, pp. 1831-1839, 2022.
- [14] S. K. P. D. P. K. M. D. T. K. B. S. H. C. K. T. P. A. B. Subashis Karmakar, «Real time detection of cognitive load using fNIRS: A deep learning approach,» *Biomedical Signal Processing and Control*, vol. 80, nº 104227, 2022.

- [15] A. U. & J. Lötsch, «Euclidean distance-optimized data transformation for cluster analysis in biomedical data (EDOtrans),» *BMC Bioinformatics volume* , vol. 23, nº 233, 2022.
- [16] J. D. L. C. & R. A. B. J. Jozelle C. Addawe, «Machine Learning Methods for Modeling Dengue Incidence in Local Communities,» *Novel & Intelligent Digital Systems: Proceedings of the 2nd International Conference (NiDS 2022)* , vol. 556, pp. 392-400, 2022.
- [17] S. K. B. B. P. R. R. K. C. R. P. & S. K. Ritesh Kumar Sinha, «Role of Machine Learning Approaches in Predicting COVID-19 New Active Cases Using Multiple Models,» *Proceedings of the 6th International Conference on Advance Computing and Intelligent Engineering* , vol. 428, pp. 61-71, 2022.
- [18] S. R. M. & K. Veer, «Trends and challenges of image analysis in facial emotion recognition: a review,» *Network Modeling Analysis in Health Informatics and Bioinformatics*, vol. 11, nº 35, 2022.
- [19] M. K. R. K. S. Manoj Kumar Dutta, «Image quality improvement of old and distorted artworks using fuzzy logic technique,» *Optik*, vol. 246, nº 168252, 2022.
- [20] L. L. Y. L. Y. Y. B. G. Z. J. W. N. a. Q. Y. Jiazheng Zhou, «Both Cross-Patient and Patient-Specific Seizure Detection Based on Self-Organizing Fuzzy Logic,» *International Journal of Neural Systems*, vol. 32, nº 06, 2022.
- [21] A. C. Austin Nicolai, «Facial Emotion Recognition Using Fuzzy Systems,» *2015 IEEE International Conference on Systems, Man, and Cybernetics*, 2015.
- [22] S. K. S. & R. Gupta, «Artificial intelligence methods for analysis of electrocardiogram signals for cardiac abnormalities: state-of-the-art and future challenges,» *Artificial Intelligence Review*, nº 500, pp. 1519-1565, 2022.
- [23] R. V. & M. K. P. Gunasekaran Manogaran, «RETRACTED ARTICLE: Hybrid Recommendation System for Heart Disease Diagnosis based on Multiple Kernel Learning with Adaptive Neuro-Fuzzy Inference System,» *Multimedia Tools and Applications volume*, nº 77, p. 4379–4399 , 2022.
- [24] J. Lee y K. H. Chon, «An Autoregressive Model-Based Particle Filtering Algorithms for Extraction of Respiratory Rates as High as 90 Breaths Per Minute From Pulse Oximeter,» *IEEE Transactions on Biomedical Engineering*, vol. 57, nº 9, pp. 2158-2167, 2010.
- [25] MediaPipe, «MediaPipe,» 2020. [En línea]. Available: <https://mediapipe.dev/index.html>. [Último acceso: 2022 11 2022].
- [26] I. Kibalchich, «Prosthesis control via Mirru App using MediaPipe hand tracking,» *GoogleDevelopers*, 2021.
- [27] I. Kibalchich, «SignAll SDK: Sign language interface using MediaPipe is now available for developers,» *GoogleDevelopers*, 2021.
- [28] MediaPipe, «MediaPipe,» 2022. [En línea]. Available: [https://google.github.io/mediapipe/solutions/face\\_detection.html](https://google.github.io/mediapipe/solutions/face_detection.html). [Último acceso: 07 11 2022].
- [29] A. A. I. G. M. G. Yury Kartynnik, «Real-time Facial Surface Geometry from Monocular Video on Mobile GPUs,» *Google Research*, 2019.

- [30] Q. Z. Q. Y. Z. L. Liwei Zhang, «Assessment of Pilots Mental Fatigue Status,» *School of Biological Science and Medical Engineering, Beihang University, 100083 Beijing, China*, 2019.
- [31] C. T. D. C. J. G. T.F Cootes, «Active Shape Models Their training and application,» *Computer vision and imagen undertanding*, vol. 61, nº 1, pp. 38-59, 1995.
- [32] J. B. P. R. A. Alejandro Jaramillo, «DETECCIÓN DE FATIGA AL CONDUCIR UTILIZANDO TÉCNICAS DE VISIÓN POR COMPUTADOR,» *Programa de Tecnología Electrónica de la Universidad del Quindío*, 2012.
- [33] M. L. s.-w. S. w.-c. G. m.-z. H. m.-y. Chai, «Drowsiness monitoring based on steering wheel status,» *Transportation Research Part D: Transport and Environment*, vol. 66, pp. 95-103, 2019.
- [34] S. E. L. R. L. B. C. a. J. S. Zuojin Li, «DRIVER FATIGUE DETECTION USING APPROXIMATE ENTROPIC OF STEERING WHEEL ANGLE FROM REAL DRIVING DATA,» *International Journal of Robotics and Automation* , 2017.
- [35] S. E. L. R. L. C. J. S. Zuojin Li, «Online Detection of Driver Fatigue Using Steering Wheel Angles for Real Driving Conditions,» *Sensors*, 2017.
- [36] A. H. A. t. D. D. D. U. P. S. t. I. S. P. a. Wearability, «Muhammad Awais, Nasreen Badruddin, Micheal Drieberg,» *Sensors*, 2017.
- [37] L. B. G. W.-Y. C. Lee Boon Leng, «Wearable driver drowsiness detection system based on biomedical and motion sensors,» *IEEE SENSORS*, pp. 1-4, 2015.
- [38] Y.-H. L. S.-H. L. Ching-Hua Weng, «river Drowsiness Detection via a Hierarchical Temporal Deep Belief Network,» *In Asian Conference on Computer Vision Workshop on Driver Drowsiness Detection from Video*, 2016.
- [39] J. G. V. M. V. D. Quentin Massoz, «Multi-Timescale Drowsiness Characterization Based on a Video of a Driver's Face,» *Sensors*, vol. 18, nº 9, 2018.
- [40] P. M. Tomas Rondik, «Cognitive event-related potential waveform latency determination: Based on result of matching pursuit algorithm and Hilbert-Huang transform,» *2013 6th International Conference on Biomedical Engineering and Informatics*, pp. 16-18, 2013.
- [41] R. P. S. Sashikant Singh, «Implementation Driver Drowsiness Detection using ML/DL(Eyelid movement-based technique),» *2022 2nd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)*, pp. 28-29, 2022.
- [42] V. S. E. Vijayan, «Real time detection system of driver drowsiness based on representation learning using deep neural networks,» *Journal of Intelligent & Fuzzy Systems*, vol. 36, nº 3, pp. 1977-1985, 2019.
- [43] K. A.-K. M. K. W. A. M. J. S. J. Rateb Jabbara, «Real-time Driver Drowsiness Detection for Android Application Using Deep Neural Networks Techniques,» *Procedia Computer Science*, vol. 130, pp. 400-407, 2018.

## **ANEXOS**

Dejo las tablas de datos en formato csv y el código de proyecto en el siguiente enlace de acceso libre:

[https://drive.google.com/drive/folders/1fwxtrjYzS5WBWjFFpLwiQr3d8ovOpr?usp=share\\_link](https://drive.google.com/drive/folders/1fwxtrjYzS5WBWjFFpLwiQr3d8ovOpr?usp=share_link)