VOLUMEN 48
XXXI Verano De la Ciencia
ISSN 2395-9797
www.jovenesenlaciencia.ugto.mx

Análisis de las respuestas emocionales bajo diferentes condiciones de sueño mediante EEG y seguimiento ocular

Analysis of emotional responses under different sleep conditions using EEG and eye-tracking

Marco Uriel Illescas Flores[1], Jorge Andrés López Romero [1], Hazzly Ximena Guerrero Rico [2], Óscar Almanza Conejo [3], Mario Alberto Ibarra Manzano [3]

[1] Licenciatura en Ingeniería de Datos e Inteligencia Artificial, Departamento de Ingeniería Electrónica, División de Ingenierías del Campus Irapuato-Salamanca, Universidad de Guanajuato, Guanajuato, México
{mu.illescasflores, ja.lopezromero}@ugto.mx
[2] Licenciatura en Ingeniería Biomédica, Universidad Simón Bolívar, Colombia
hazzly.guerrero@unisimon.edu.co
[3] Departamento de Ingeniería Electrónica, División de Ingenierías del Campus Irapuato-Salamanca, Universidad de Guanajuato, Guanajuato, México
{o.almanza, ibarram}@ugto.mx

Resumen

En este contexto, el estudio se orienta al análisis de las respuestas emocionales en distintas condiciones de sueño, utilizando la base de datos SEED-SD. Esta recopila información de 40 participantes expuestos, en cada sesión, a 24 videoclips asociados a la felicidad, la tristeza, el miedo y la neutralidad, bajo condiciones de privación, recuperación y sueño normal. Durante la visualización, se registraron señales EEG en 62 canales y datos de seguimiento ocular. A partir de estos registros, se obtuvieron características de entropía diferencial en cinco bandas de frecuencia y 50 variables oculares relacionadas con el diámetro pupilar, las fijaciones, las sacadas y otros eventos visuales.
La disponibilidad conjunta de estas dos modalidades permite estudiar con mayor precisión cómo varía el procesamiento emocional en las distintas condiciones de sueño. Resultados recientes obtenidos con SEED-SD sugieren que la privación del sueño reduce el rendimiento en el reconocimiento emocional frente a las condiciones de recuperación y de sueño normal, además de modificar los patrones fisiológicos asociados a las emociones. En consecuencia, el análisis combinado de las características EEG y oculares constituye una estrategia útil para examinar las diferencias en la discriminación de felicidad, tristeza, miedo y neutralidad mediante análisis estadístico y modelos de aprendizaje automático.

Palabras clave: Sueño; Emociones; Electroencefalograma; Seguimiento ocular; Aprendizaje automático; SEED-SD.

1. Introducción

El sueño es un proceso fisiológico esencial para la recuperación del sistema nervioso y el mantenimiento de funciones como la atención, la memoria, la toma de decisiones y la regulación emocional. Cuando su duración o calidad se altera, también puede modificarse la manera en que las personas perciben, interpretan y responden a los estímulos emocionales. Diversas investigaciones han señalado que la privación del sueño puede afectar el reconocimiento de emociones, incrementar la reactividad emocional y alterar la regulación de estructuras cerebrales relacionadas con el procesamiento afectivo (Beattie et al., 2015; Killgore et al., 2017). Estos cambios repercuten en el desempeño académico, laboral y social, por lo que resulta importante analizar el impacto de las distintas condiciones de sueño, como la privación, la recuperación y el sueño normal, sobre el reconocimiento de emociones.

Las emociones son respuestas complejas que comprenden experiencias subjetivas, cambios fisiológicos y manifestaciones conductuales. Entre las emociones básicas se encuentran la felicidad, la tristeza y el miedo, mientras que el estado neutral puede utilizarse como condición de referencia para analizar las variaciones producidas durante la exposición a distintos estímulos. Sin embargo, la evaluación mediante cuestionarios o autoevaluaciones puede verse influida por la percepción individual del participante, por lo que el análisis de señales fisiológicas constituye una alternativa para obtener información más objetiva sobre las respuestas emocionales.

Entre estas señales fisiológicas, destaca el electroencefalograma (EEG), que permite registrar de forma no invasiva la actividad eléctrica cerebral y analizar sus variaciones temporales, espaciales y espectrales asociadas al procesamiento emocional. En este campo, las características extraídas de las bandas delta, theta, alfa, beta y gamma han demostrado ser útiles para diferenciar estados emocionales mediante técnicas de aprendizaje automático y profundo (Almanza-Conejo et al., 2023).

De manera complementaria, el seguimiento ocular proporciona información sobre la atención visual y la activación fisiológica durante la exposición a estímulos emocionales. Variables como el diámetro pupilar, la duración y la dispersión de las fijaciones, así como la amplitud, la duración y la frecuencia de las sacadas, permiten caracterizar la respuesta del movimiento ocular. Aunque estas medidas también pueden verse afectadas por factores como la iluminación, la fatiga o la carga cognitiva, su combinación con el EEG proporciona una representación más completa de la experiencia emocional, ya que la integración de ambas modalidades mejora la clasificación al reunir información cerebral y ocular complementaria (Lu et al., 2015; Zheng et al., 2019). En este marco, se plantea analizar cómo las condiciones de sueño influyen en el reconocimiento emocional a partir de estas modalidades fisiológicas.

2. Metodología

2.1 Base de datos y caracterización exploratoria de la respuesta emocional

El presente trabajo empleó el conjunto de datos SEED-SD, diseñado para estudiar el reconocimiento de emociones en distintas condiciones de sueño. La base de datos está conformada por registros electroencefalográficos (EEG) y de seguimiento ocular obtenidos de 40 participantes sanos (20 hombres y 20 mujeres), con edades entre 18 y 32 años, quienes completaron tres sesiones experimentales correspondientes a privación de sueño (SD), recuperación del sueño (SR) y sueño normal (SN). En cada sesión, los participantes visualizaron 24 videoclips distribuidos equitativamente entre cuatro categorías emocionales: felicidad, tristeza, miedo y estado neutral.

Para el análisis de las señales EEG, se emplearon las características de Entropía Diferencial (DE) proporcionadas por la base de datos. Estas características representan la actividad espectral registrada en las bandas delta, theta, alfa, beta y gamma en cada uno de los 62 canales del sistema EEG.

De manera complementaria, se utilizaron las 50 características de seguimiento ocular incluidas en SEED-SD. Estas variables se dividieron en cinco grupos: diámetro pupilar, dispersión de las fijaciones, duración de las fijaciones, características de las sacadas y estadísticas de eventos oculares. Para el diámetro pupilar, la dispersión de las fijaciones, la duración de las fijaciones y las sacadas, se incluyeron características de Entropía Diferencial en cuatro intervalos de frecuencia entre 0 y 1 Hz, además de medidas como la media y la desviación estándar. Las estadísticas de eventos incluyeron la frecuencia de fijaciones y sacadas, así como su duración, amplitud, dispersión y latencia. La distribución completa de estas características se presenta en la Tabla 1. En total, cada registro estuvo formado inicialmente por 310 características EEG y 50 características oculares, lo que sumó 360 características combinadas.

Como etapa inicial del estudio, se realizó un análisis exploratorio para examinar el comportamiento de la respuesta emocional asociada a la actividad EEG en cada una de las condiciones de sueño: privación, recuperación y sueño normal. Para ello, se calcularon los valores promedio de la Entropía Diferencial de las bandas delta, theta, alfa, beta y gamma para cada categoría emocional. El uso del promedio permitió integrar la información de múltiples ventanas temporales generadas a partir de los videoclips y obtener una representación global de la actividad cerebral, reduciendo la variabilidad de las observaciones individuales y facilitando la comparación entre emociones y condiciones experimentales. A partir de estos valores, se elaboraron gráficas comparativas para visualizar las variaciones en la respuesta emocional entre las tres condiciones de sueño e identificar tendencias generales en el comportamiento de las bandas de frecuencia. Este análisis tuvo un alcance descriptivo y constituyó una primera aproximación al efecto de las condiciones de sueño sobre el procesamiento emocional, antes de desarrollar los modelos de clasificación.

VOLUMEN 48
XXXI Verano De la Ciencia
ISSN 2395-9797
www.jovenesenlaciencia.ugto.mx

Tabla 1. Distribución de las 50 características de seguimiento ocular proporcionadas por la base de datos SEED-SD. Se incluyen variables relacionadas con el diámetro pupilar, las fijaciones, las sacadas y las estadísticas de eventos oculares. Adaptado de Li et al. (2025).

Name	Dimensions	Details
Pupil diameter (px)	1-12	DE features of the pupil diameters along the X and Y axes in 4 frequency bands (0-0.2 Hz, 0.2-0.4 Hz, 0.4-0.6 Hz and 0.6-1 Hz); means of the pupil diameters along the X and Y axes; standard deviations of the pupil diameters along the X and Y axes.
Fixation dispersion (px)	13-24	DE features of the fixation dispersion along the X and Y axes in 4 frequency bands (0-0.2 Hz, 0.2-0.4 Hz, 0.4-0.6 Hz and 0.6-1 Hz); means of the fixation dispersion along the X and Y axes; standard deviations of the fixation dispersion along the X and Y axes.
Fixation duration (ms)	25-30	DE features of fixation duration in 4 bands (0-0.2 Hz, 0.2-0.4 Hz, 0.4-0.6 Hz and 0.6-1 Hz); mean and standard deviation of fixation duration.
Saccade	31-42	DE features of the saccade durations (ms) and saccade amplitudes (°) in 4 bands (0-0.2 Hz, 0.2-0.4 Hz, 0.4-0.6 Hz and 0.6-1 Hz); means of saccade durations and amplitudes; standard deviations of saccade durations and amplitudes
Event statistics	43-50	Fixation frequency (count/s), maximum fixation duration (ms), total fixation dispersion (px), maximum fixation dispersion (px), saccade frequency (count/s), average saccade duration (ms), average saccade amplitude, (°) average saccade latency (ms).

2.2 Procesamiento y unidad de análisis

Una vez descrito el conjunto de datos, se procedió al procesamiento de las características utilizadas para entrenar los modelos de aprendizaje automático. En primer lugar, se verificó que los registros de EEG y de seguimiento ocular correspondieran al mismo sujeto, a la misma sesión y al mismo videoclip. Posteriormente, se revisó la presencia de datos faltantes, valores infinitos y registros duplicados antes de construir las distintas representaciones del conjunto de datos.

La información original estaba dividida en 97,800 ventanas de cuatro segundos. En la primera forma de representar los datos se obtuvo una sola observación por sujeto, sesión y videoclip, calculando el promedio de cada característica en todas las ventanas del mismo clip. Con esto se obtuvieron 2,880 observaciones. Cada observación incluyó 310 características de EEG y 50 de oculares, para un total de 360 características en la modalidad combinada EEG+Eye. Los identificadores de sujeto, sesión, clip y sexo se conservaron únicamente como datos de control y no se utilizaron como entradas para los clasificadores.

Después, se agregó una segunda representación para conservar parte de la información temporal. Cada clip se dividió en cuatro bloques y, en cada uno, se calcularon cinco medidas: media, desviación estándar, mínimo, máximo y mediana. De esta manera, se generaron inicialmente 7,200 características por clip, al multiplicar las 360 características originales por 4 bloques y 5 medidas. Debido a que este número era muy grande, estas características no se enviaron todas directamente al clasificador, sino que primero se aplicó una selección de variables durante el proceso de entrenamiento.

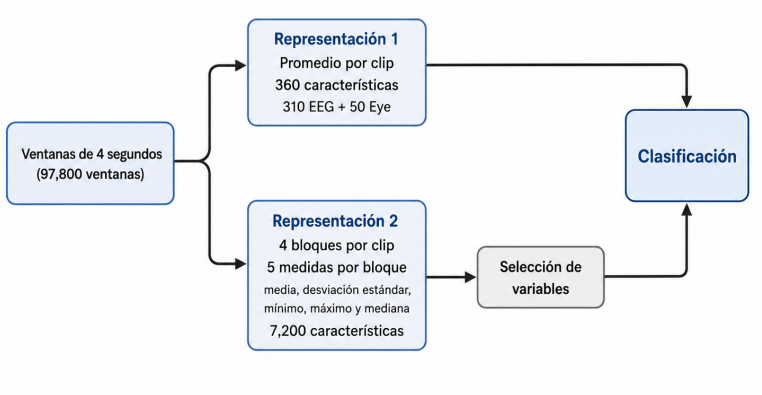


Figura 1. Proceso general para preparar las características y entrenar los clasificadores.

2.3 Definición de los problemas de clasificación

Se trabajó con dos enfoques de clasificación. El primer enfoque, denominado C1, tuvo como objetivo predecir la emoción expresada en el videoclip. Las clases fueron neutras: tristeza, miedo y felicidad. Este enfoque se realizó de forma general, usando las tres condiciones de sueño en conjunto, y también por separado: privación del sueño, recuperación del sueño y sueño normal.

El segundo enfoque, llamado C2, tuvo como objetivo predecir la condición de sueño, con clases de privación, recuperación y sueño normal. En este caso, se mantuvo fija una emoción para observar si la condición de sueño podía distinguirse cuando los clips correspondían únicamente a neutralidad, tristeza, miedo o felicidad.

***Tabla 2**. Problemas de clasificación utilizados en el estudio.*

Identificador	Objetivo	Datos incluidos	Clases
C1-G	Predecir emoción	Todas las condiciones de sueño	Neutral, tristeza, miedo y felicidad
C1-SD	Predecir emoción	Solo privación del sueño	Neutral, tristeza, miedo y felicidad
C1-SR	Predecir emoción	Solo recuperación del sueño	Neutral, tristeza, miedo y felicidad
C1-NS	Predecir emoción	Solo sueño normal	Neutral, tristeza, miedo y felicidad
C2-NEU	Predecir condición de sueño	Solo clips neutrales	Privación, recuperación y sueño normal

C2-SAD	Predecir condición de sueño	Solo clips de tristeza	Privación, recuperación y sueño normal
C2-FEA	Predecir condición de sueño	Solo clips de miedo	Privación, recuperación y sueño normal
C2-HAP	Predecir condición de sueño	Solo clips de felicidad	Privación, recuperación y sueño normal

2.4 Partición de los datos

La partición de los datos se realizó por sujetos y no por clips individuales. De los 40 participantes, 32 sujetos completos se utilizaron para el entrenamiento y la selección de hiperparámetros, mientras que ocho sujetos completos se apartaron como conjunto de prueba o test. La partición también mantuvo el equilibrio por sexo, con 16 mujeres y 16 hombres en entrenamiento y 4 mujeres y 4 hombres en la prueba. Se utilizó la semilla 20260710 para que la división pudiera repetirse.

Esta separación se hizo de esta manera para que los clips de una misma persona no aparecieran simultáneamente en entrenamiento y en prueba. Si esto hubiera ocurrido, el modelo podría aprender patrones propios de la persona y aparentar un mejor resultado. El conjunto de prueba no participó en el escalado, la selección de características ni la búsqueda de hiperparámetros.

Entre los 32 sujetos de entrenamiento, se aplicó la validación cruzada agrupada en tres particiones. Los grupos tuvieron 11, 11 y 10 sujetos. En cada repetición se entrenó con dos grupos y se validó con el grupo restante. Al terminar esta parte, se eligió la configuración con el mayor promedio macro de F1. Después, el modelo seleccionado se ajustó nuevamente con los 32 sujetos y se evaluó una sola vez con los 8 sujetos apartados.

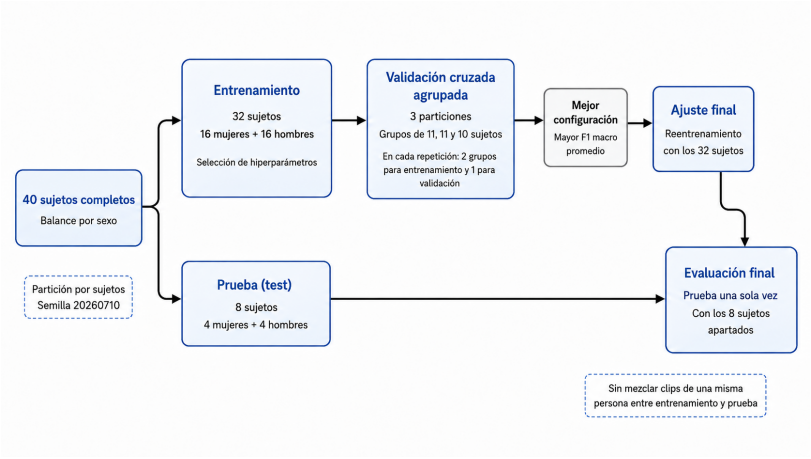


Figura 2. Separación por sujetos empleada para entrenamiento, validación y prueba.

2.5 Clasificadores evaluados

En la primera etapa se completaron 73 configuraciones experimentales. Esto no quiere decir que se usaron 73 tipos de algoritmos diferentes, sino que una configuración fue la combinación de una tarea, una modalidad y un modelo. Se utilizaron seis tipos de clasificadores: clasificador dummy de referencia, regresión logística, k vecinos más cercanos, máquina de soporte vectorial lineal, máquina de soporte vectorial con kernel RBF y Random Forest.

De las 73 configuraciones, 37 utilizaron solo EEG y 36 utilizaron EEG+Eye. Random Forest, regresión logística y SVM con RBF se evaluaron en 16 configuraciones cada uno; el clasificador aleatorio, en nueve;

KNN, en ocho; y SVM lineal, en ocho. El clasificador dummy se incluyó como referencia para comprobar que los modelos entrenados superarían el comportamiento aleatorio.

***Tabla 3**. Clasificadores utilizados en la primera etapa.*

Clasificador	Función dentro del estudio	Configuraciones completadas
Clasificador aleatorio	Referencia de azar	9
Regresión logística	Modelo lineal de referencia	16
KNN	Clasificación por cercanía entre observaciones	8
SVM lineal	Separación lineal con margen	8
SVM RBF	Separación no lineal	16
Random Forest	Modelo no lineal basado en varios árboles	16

Después de esta comparación, se dio prioridad a Random Forest, regresión logística y SVM lineal en la modalidad EEG+Eye. Esta decisión se tomó para concentrar la búsqueda en los modelos más útiles y reducir el tiempo de cómputo. En esta segunda etapa se programaron 23 configuraciones, correspondientes a los tres modelos en los ocho problemas de clasificación.

En la etapa final se ejecutaron 28 configuraciones. Veinticuatro utilizaron las 360 características resumidas por clip con Random Forest, regresión logística y SVM lineal. Las cuatro configuraciones restantes utilizaron los clips divididos en cuatro bloques y Random Forest para C1-G, C1-SD, C1-SR y C1-NS. Random Forest fue incluido en esta representación porque puede manejar relaciones no lineales e interacciones entre características. La explicación de por qué obtuvo los mejores resultados en varios casos se presenta en la sección de resultados y no en esta parte.

2.6 Preprocesamiento y escalado

La regresión logística, KNN y los dos tipos de SVM utilizaron la estandarización con StandardScaler. Con esto, cada característica se transformó a partir de su media y su desviación estándar en los datos de entrenamiento. Para EEG y Eye se utilizaron escaladores separados porque se trata de dos tipos de información distintos. Random Forest y el clasificador aleatorio no requirieron escalado.

Todos los pasos se integraron en un único pipeline. Esto significa que el escalado y la selección de características se recalculaban únicamente a partir de la porción de entrenamiento de cada partición. Así se evitó utilizar, de forma indirecta, información de validación o de prueba antes de medir el modelo.

2.7 Selección de características

En la primera etapa se utilizaron todas las características, ya que el objetivo era comparar los clasificadores y las modalidades. En la etapa de optimización se aplicó SelectKBest con ANOVA F. Este método asignó una puntuación a cada característica según su relación con las clases. Se probaron subconjuntos de 50, 100, 150 y 250 características, además de la opción de usar todas las variables. La cantidad final se eligió mediante F1 macro durante la validación cruzada.

En la etapa final se utilizó una aproximación de máxima relevancia y mínima redundancia, conocida como mRMR. Primero se calculó la relevancia mediante ANOVA F y luego se redujo la selección de características con información muy repetida, utilizando la correlación entre ellas. Se usaron un umbral de correlación de 0.92 y un peso de redundancia de 0.35. Para la representación de 360 variables se probaron 50, 100, 150,

250 y todas las características. Para la representación temporal de 7,200 variables se probaron 100, 250, 500 y 1,000 características.

La selección se realizó dentro de cada partición de validación y nunca antes de separar los datos. Por esta razón, las características elegidas podían variar ligeramente entre particiones. Al final, también se obtuvieron las importancias por característica y se agruparon por modalidad, banda de EEG y tipo de variable ocular. Las importancias finales se calcularon con el modelo seleccionado, mientras que mRMR se utilizó para determinar qué variables entraban en él.

2.8 Búsqueda de hiperparámetros

Los hiperparámetros se eligieron utilizando únicamente los 32 sujetos de entrenamiento y la validación cruzada en tres particiones. La medida principal para seleccionar cada configuración fue el F1 macro promedio. En la primera etapa se utilizó una cuadrícula cerrada y relativamente pequeña, como se muestra en la Tabla 3.

Tabla 4. *Hiperparámetros evaluados en la primera etapa.*

Modelo	Hiperparámetros evaluados
Clasificador aleatorio	Estrategia estratificada
Regresión logística	C = 0.1, 1 y 10; peso de clase normal o balanceado
KNN	Vecinos = 3, 5, 9 y 15; pesos uniformes o por distancia
SVM lineal	C = 0.1, 1 y 10; peso de clase normal o balanceado
SVM RBF	C = 1, 10 y 100; gamma = scale, 0.001 y 0.01; peso de clase normal o balanceado
Random Forest	300 árboles; profundidad sin límite, 10 o 20; máximo de características sqrt o 0.5; peso de clase normal o balanceado

En la segunda etapa se amplió la búsqueda. Para la regresión logística se probaron valores de C desde 0.01 hasta 10, penalizaciones L1 y L2, y pesos de clase normales o balanceados. Para el SVM lineal se probaron valores de C de 0.001 a 10 y las dos opciones de peso de clase. En Random Forest se probaron 300, 500 y 800 árboles; profundidades de 8, 12, 20, 32 o sin límite; diferentes cantidades mínimas de observaciones por hoja y de división; distintas cantidades de características por árbol y tres opciones de ponderación de clases. Dado que había muchas combinaciones de Random Forest, se realizó una búsqueda aleatoria de 28 candidatos por configuración.

Para la búsqueda final, se reutilizaron como punto de partida los hiperparámetros que habían funcionado mejor anteriormente, pero también se probaron combinaciones cercanas. Para Random Forest se probaron hasta 18 candidatos, para regresión logística 16 y para SVM lineal 10. Cada candidato fue evaluado en las tres particiones internas. En Random Forest se consideraron entre 300 y 800 árboles, profundidades de 12, 20 o sin límite, y diferentes valores del número de variables, del tamaño de hoja y del peso de clase. Para la regresión logística y el SVM lineal se probaron distintos valores de C y del peso de clase. También se evaluó, al mismo tiempo, la cantidad de características seleccionadas.

2.9 Evaluación de los modelos

La medida principal fue F1 macro porque calcula el F1 de cada clase por separado y luego obtiene el promedio, dando la misma importancia a neutralidad, tristeza, miedo y felicidad, o a las tres condiciones de sueño. Como medida secundaria, se utilizó el accuracy, que representa la proporción de predicciones correctas.

También se calcularon el balanced accuracy, la precisión, el recall y el F1 de cada clase. Para observar los tipos de error, se guardaron matrices de confusión tanto en valores absolutos como en valores normalizados. Los valores de validación cruzada se reportaron como promedio y desviación estándar, mientras que el conjunto de prueba se reportó por separado. No se mezclaron los resultados de validación con los de prueba.

2.10 Equipo de cómputo y software

Los experimentos se ejecutaron en una computadora con Windows de 64 bits, un procesador Intel con 20 núcleos lógicos, 32 GB de memoria RAM y una tarjeta gráfica NVIDIA GeForce RTX 5060 Ti con 16 GB de memoria de video (VRAM).

El código se ejecutó con Python 3.11.9. Las principales bibliotecas fueron scikit-learn 1.9.0, NumPy 2.4.6, pandas 3.0.3, SciPy 1.17.1, Matplotlib 3.11.0 y Seaborn 0.13.2. Los datos de las representaciones temporales se almacenaron en formato float32 para reducir el consumo de memoria.

3. Resultados

Como primera aproximación al comportamiento de la respuesta emocional bajo distintas condiciones de sueño, se analizaron los valores promedio de Entropía Diferencial correspondientes a las bandas delta, theta, alfa, beta y gamma para las emociones de neutralidad, tristeza, miedo y felicidad. La Figura 3 presenta esta comparación en las condiciones de privación de sueño, de recuperación del sueño y de sueño normal.

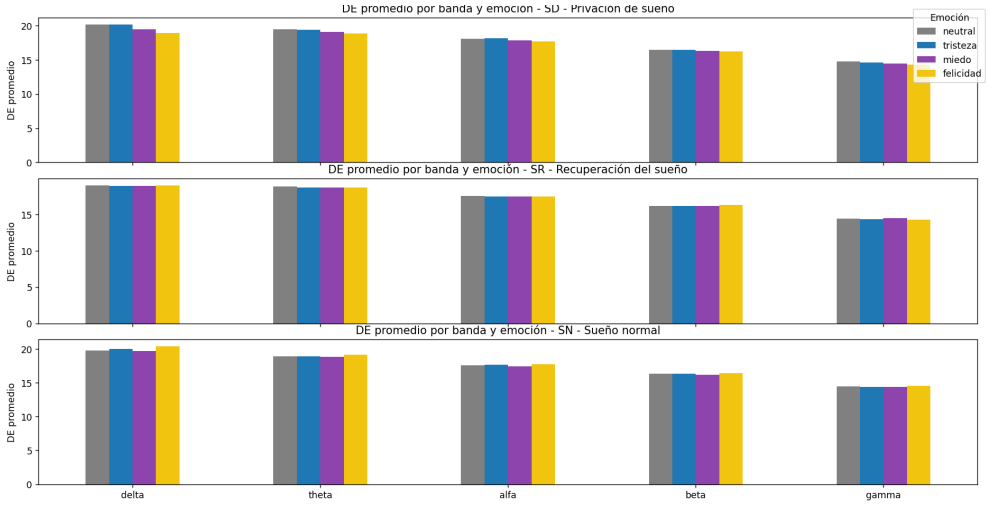


Figura 3. Valores promedio de Entropía Diferencial por banda de frecuencia y categoría emocional en las condiciones de privación de sueño, recuperación del sueño y sueño normal.

En general, la Figura 3 muestra un patrón descendente de la Entropía Diferencial desde la banda delta hasta la gamma en las tres condiciones de sueño. Dentro de cada banda, los valores de las cuatro categorías emocionales se mantuvieron próximos entre sí, lo que indica que las diferencias entre emociones no se manifestaron como cambios significativos en los valores globales. No obstante, se observaron variaciones en la descripción del orden relativo de las emociones según la condición experimental. Durante la privación del sueño, la tristeza presentó los valores más altos en las bandas delta y alfa, mientras que la felicidad tendió a presentar valores inferiores en la mayoría de las bandas. En la recuperación del sueño, las respuestas

VOLUMEN 48
XXXI Verano De la Ciencia
ISSN 2395-9797
www.jovenesenlaciencia.ugto.mx

emocionales mostraron una mayor homogeneidad. En el sueño normal, la felicidad alcanzó valores ligeramente superiores en las bandas delta, theta, alfa y gamma.

Estos resultados sugieren que las condiciones de sueño podrían modificar sutilmente la organización espectral de la respuesta emocional, más que producir aumentos o disminuciones uniformes en una sola banda. Esta interpretación es consistente con estudios que señalan que el reconocimiento emocional depende de patrones distribuidos en distintas bandas y regiones cerebrales, y que las bandas beta y gamma pueden aportar información relevante para la discriminación de estados emocionales cuando se analizan conjuntamente con la localización de los canales y otras características del EEG (Almanza-Conejo et al., 2023; Almanza-Conejo et al., 2025).

Sin embargo, dado que la figura integra múltiples ventanas, sujetos y canales en valores promedio, las diferencias observadas deben interpretarse como tendencias descriptivas. La proximidad entre las barras no implica necesariamente la ausencia de información discriminativa, ya que esta puede residir en la distribución espacial de la actividad entre los 62 canales o en combinaciones de bandas que no son visibles en una representación global. La base SEED-SD conserva las características de Entropía Diferencial por ventana, banda y canal, con una dimensionalidad de 310 características EEG, lo que permite que los modelos posteriores analicen patrones más complejos que los mostrados en esta figura.

Para complementar el análisis anterior, se calculó el cambio estandarizado de la Entropía Diferencial en las condiciones de privación y recuperación del sueño, utilizando el sueño normal como condición de referencia. La Figura 4 permite observar la dirección y la magnitud de las variaciones para cada emoción y cada banda de frecuencia. Los valores positivos indican un aumento respecto al sueño normal, mientras que los valores negativos representan una disminución.

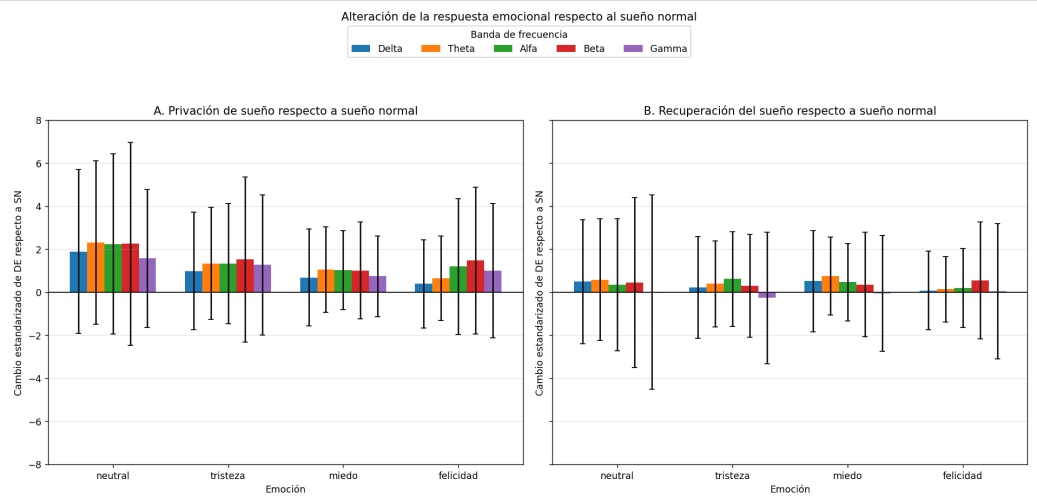


Figura 4. Cambio estandarizado de la Entropía Diferencial por emoción y por banda de frecuencia en las condiciones de privación y recuperación del sueño, tomando como referencia el sueño normal. Las barras de error representan la variabilidad de los datos.

En la condición de privación del sueño se observaron cambios positivos en todas las emociones y bandas de frecuencia, lo que indica valores de Entropía Diferencial superiores a los registrados durante el sueño normal. La alteración fue más marcada en la emoción neutral, especialmente en las bandas theta, alfa y beta. La tristeza y el miedo presentaron incrementos intermedios, mientras que en la felicidad los mayores cambios se observaron en las bandas alfa y beta.

En contraste, la condición de recuperación del sueño mostró variaciones de menor magnitud y más cercanas a cero. La mayoría de las bandas conservaron cambios ligeramente positivos, aunque la banda gamma presentó valores cercanos a cero o negativos en tristeza y en miedo. Este comportamiento sugiere que la recuperación del sueño vuelve a aproximar la respuesta EEG a los niveles observados durante el sueño normal, aunque no necesariamente produce una restitución completa y uniforme en todas las emociones y bandas.

En conjunto, la comparación muestra que la privación del sueño provoca una alteración más amplia de la respuesta emocional que la recuperación. Sin embargo, las barras de error son amplias y se superponen al valor cero en varios casos, por lo que las diferencias deben interpretarse como tendencias descriptivas hasta confirmar su significancia mediante pruebas estadísticas.

3.2 Ejecución de los clasificadores

En la primera etapa se completaron 73 configuraciones formadas por diferentes tareas, modalidades y clasificadores. Esta parte permitió comparar seis algoritmos y observar la diferencia entre usar solo EEG y usarlo junto con las características oculares. Después se realizó una segunda etapa enfocada en EEG+Eye, regresión logística, SVM lineal y Random Forest. En esta etapa se obtuvieron 23 configuraciones completas de las 24 programadas. Finalmente, se completaron 28 configuraciones con selección de características y con ambas formas de representación de cada clip. No se presentaron configuraciones fallidas ni interrupciones durante la ejecución final.

3.3 Comparación entre EEG y EEG+Eye

La combinación de EEG y seguimiento ocular obtuvo mejores resultados que el EEG por sí solo en los cuatro problemas de reconocimiento de emociones. Al comparar los cinco modelos predictivos en cada problema C1, las 20 comparaciones mostraron un aumento del F1 macro en el conjunto de prueba al incorporar las variables oculares. El aumento promedio fue de 0.118 para C1-G, 0.110 para C1-NS, 0.137 para C1-SD y 0.106 para C1-SR.

El cambio más grande se observó en Random Forest para C1-SD, donde el F1 macro aumentó aproximadamente 0.284 al pasar de EEG a EEG+Eye. Para C2, el comportamiento fue menos constante: agregar Eye ayudó en varias combinaciones, pero en otras el cambio fue pequeño o negativo. Esto indicó que la fusión multimodal fue más clara para reconocer emociones que para distinguir la condición de sueño.

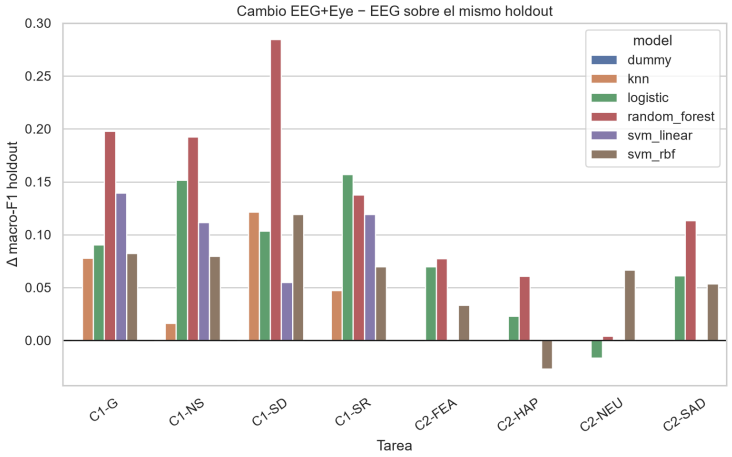


Figura 5. Cambio en la macro F1 del conjunto de prueba al utilizar EEG+Eye en lugar de solamente EEG.

3.4 Resultados de los modelos seleccionados

La selección principal de cada modelo se realizó con el promedio macro F1 de la validación cruzada interna. Después de elegir el modelo y sus hiperparámetros, se reportó su comportamiento en los ocho sujetos del conjunto de prueba. De esta manera, el conjunto de prueba no fue el criterio para elegir el modelo en cada tarea.

Tabla 5. Modelos seleccionados mediante validación cruzada y sus resultados en el conjunto de prueba.

Tarea	Modelo Rep. y k	F1 macro de validación	Prueba: accuracy/F1 macro
C1-G	Regresión logística P360, 50	0.535 ± 0.051	0.502/0.496
C1-NS	Random Forest B4, 1,000	0.607 ± 0.020	0.594/0.591
C1-SD	SVM lineal P360, 250	0.531 ± 0.048	0.469/0.468
C1-SR	Random Forest B4, 500	0.569 ± 0.016	0.594/0.581
C2-FEA	Random Forest P360, 250	0.489 ± 0.033	0.493/0.485
C2-HAP	Regresión logística P360, 50	0.480 ± 0.029	0.514/0.509
C2-NEU	SVM lineal P360, todas	0.467 ± 0.039	0.465/0.454
C2-SAD	Random Forest P360, todas	0.462 ± 0.007	0.521/0.504

En C1, el mejor resultado seleccionado fue C1-NS, que reconoce las cuatro emociones en la condición de sueño normal. Random Forest con los clips divididos en cuatro bloques obtuvo un accuracy de 0.594 y un F1 macro de 0.591. El segundo resultado fue C1-SR, correspondiente a la recuperación del sueño, también con representación en cuatro bloques y Random Forest. Este modelo obtuvo un accuracy de 0.594 y un F1 macro de 0.581.

En C1-G, donde se combinaron las tres condiciones de sueño, la regresión logística obtuvo un accuracy de 0.502 y un F1 macro de 0.496. Para la privación del sueño, el modelo seleccionado mediante validación fue el SVM lineal, que obtuvo un accuracy de 0.469 y un F1 macro de 0.468. De forma descriptiva, estos valores muestran un reconocimiento más alto en sueño normal y en recuperación que en privación, pero no permiten concluir que la condición de sueño fue la única causa, ya que los modelos seleccionados y la representación no fueron exactamente los mismos en todos los casos.

Los resultados de C1 superaron el valor esperado por azar de 0.25 en cuatro emociones. Sin embargo, la diferencia entre los valores de las condiciones también muestra que todavía hubo varios clips confundidos con otra emoción.

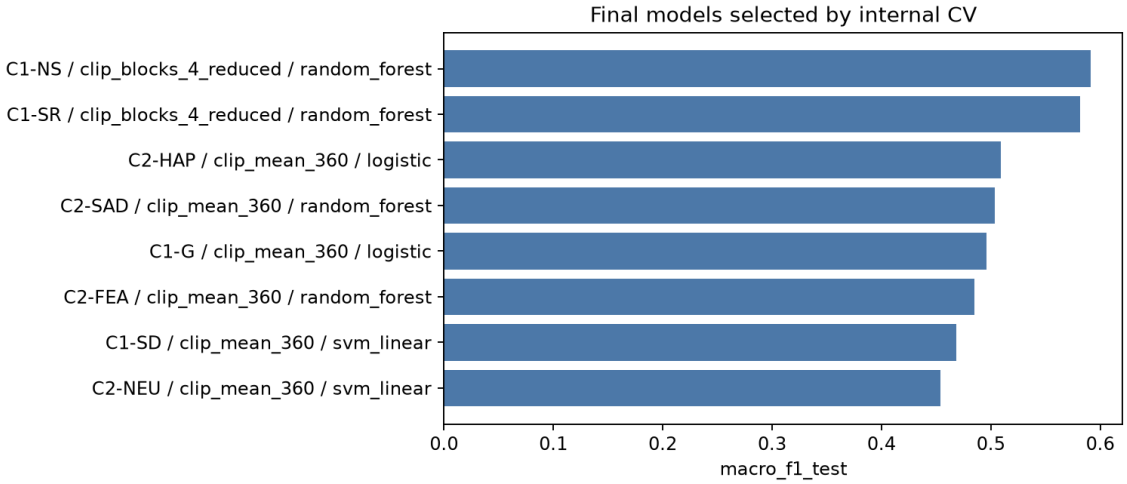


Figura 6. F1 macro en el conjunto de prueba de los modelos finales seleccionados mediante validación cruzada interna.

3.5 Análisis del mejor modelo de reconocimiento emocional

En la matriz de confusión del modelo C1-NS se observó que la clase 'neutral' fue la de mayor recall, con 0.71. Después se encontró miedo con 0.62, felicidad con 0.56 y tristeza con 0.48. La tristeza fue confundida principalmente con la neutralidad y el miedo. La felicidad también se confundió con la neutralidad y el miedo, mientras que la neutralidad tuvo menos confusión con el miedo.

Los valores de F1 por emoción fueron 0.654 para neutral, 0.511 para tristeza, 0.619 para miedo y 0.581 para felicidad. Esto muestra que el resultado general de 0.591 no se debió únicamente a una sola clase. Aun así, la tristeza siguió siendo la emoción más difícil para este modelo.

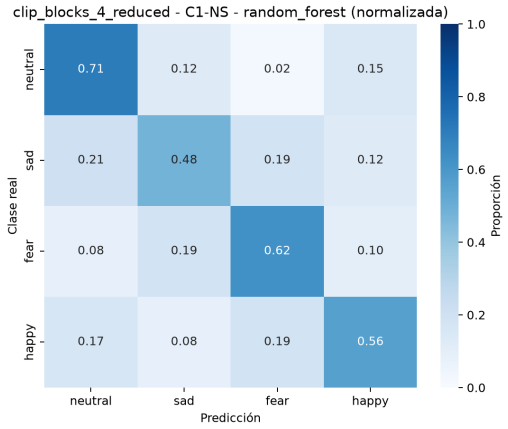


Figura 7. Matriz de confusión normalizada de Random Forest para el reconocimiento de emociones durante el sueño normal.

3.6 Resultados para la clasificación de la condición de sueño

En C2 se intentó distinguir entre privación, recuperación y sueño normal mediante clips de una sola emoción. El mejor F1 macro seleccionado en el conjunto de prueba fue de 0.509 para C2-HAP, utilizando regresión logística. Después se encontró C2-SAD con 0.504, C2-FEA con 0.485 y C2-NEU con 0.454. Todos estos

valores quedaron por encima del nivel de azar de aproximadamente 0.333, aunque se situaron por debajo de los mejores resultados en reconocimiento emocional.

En C2-HAP, el recall fue de 0.65 en privación, 0.40 en recuperación y 0.50 en sueño normal. En C2-SAD, Random Forest obtuvo un F1 de 0.605 para privación, 0.425 para recuperación y 0.481 para sueño normal. En C2-NEU también se observó que la recuperación fue la clase más difícil. Estos resultados muestran que sí existió información para diferenciar las condiciones, pero la separación entre la recuperación y las otras dos condiciones aún fue limitada.

No se realizó un único C2 general como resultado principal, ya que en este enfoque se dejó fija la emoción. De esta manera, C2-HAP, C2-SAD, C2-FEA y C2-NEU responden por separado a qué ocurrió con la condición de sueño cuando los clips correspondían a felicidad, tristeza, miedo o neutralidad.

3.7 Efecto de dividir los clips en cuatro bloques

La representación de cuatro bloques mejoró los resultados en algunas tareas, pero no en todas. En la comparación interna de C1, el cambio promedio del F1 macro en validación fue de solo 0.0046 respecto al promedio por clip. Dos de las cuatro tareas mejoraron y dos no. Por ello, no se puede decir que aumentar de 360 a 7,200 características haya sido mejor en general.

Esta representación sí fue seleccionada para C1-NS y C1-SR. C1-NS obtuvo el mejor resultado final, mientras que C1-SR también alcanzó un resultado alto. En C1-G, la representación temporal no mejoró lo suficiente y se mantuvo en un promedio de 360 características. En C1-SD, la selección principal también mantuvo las 360 características, aunque algunas configuraciones de Random Forest con bloques presentaron valores descriptivos elevados en el conjunto de prueba.

La etapa final mejoró el F1 macro de prueba en tres de las ocho tareas respecto de la optimización anterior. Los cambios más claros se observaron en C1-SR, con un aumento de 0.083, y en C1-NS, con un aumento de 0.030. En C2-FEA el aumento fue de 0.016. C1-G, C1-SD, C2-HAP y C2-NEU no mejoraron en la prueba, mientras que C2-SAD se mantuvo igual. Por lo tanto, la selección de características y los bloques temporales aportaron mejoras específicas, aunque no en todos los clasificadores.

3.8 Características con mayor importancia

La importancia de las características se obtuvo del Random Forest seleccionado para C1-NS, que resultó ser el mejor modelo final. Las variables individuales de mayor importancia fueron principalmente oculares. La característica más importante fue la mediana del primer bloque de la variable correspondiente al diámetro pupilar medio en el eje X. Después aparecieron el mínimo de la amplitud de sacada en la banda de 0 a 0.2 Hz durante el segundo bloque y el mínimo del diámetro pupilar Y durante el primer bloque.

Tabla 6*. Diez características individuales de mayor importancia en el modelo C1-NS.*

Posición	Característica	Descripción	Importancia
1	b1__eye_09__median	Mediana de la variable de diámetro pupilar medio en X durante el bloque 1	0.0997
2	b2__eye_35__min	Mínimo de la amplitud de sacada DE 0–0.2 Hz en el bloque 2	0.0362
3	b1__eye_10__min	Mínimo del diámetro pupilar y en el bloque 1	0.0239
4	b1__eye_29__std	Desviación de la duración media de fijación en el bloque 1	0.0113

5	b1__eye_15__std	Desviación de la dispersión de fijación X DE 0.4–0.6 Hz en el bloque 1	0.0082
6	b3__eye_14__std	Desviación de la dispersión de fijación X DE 0.2–0.4 Hz en el bloque 3	0.0069
7	b2__eye_29__std	Desviación de la duración media de fijación en el bloque 2	0.0054
8	b2__eye_35__std	Desviación de la amplitud de sacada DE 0–0.2 Hz en el bloque 2	0.0044
9	b3__eye_21__std	Desviación de la dispersión media de fijación X en el bloque 3	0.0040
10	b1__gamma_ch16__std	Desviación de gamma en el canal 16 durante el bloque 1	0.0036

Al sumar la importancia por grupos, gamma tuvo el valor más alto, con 0.202, seguido de beta, con 0.154; variables pupilares, con 0.134; theta, con 0.126; delta, con 0.126; y alfa, con 0.107. También aparecieron las sacadas con 0.075, la dispersión de las fijaciones con 0.041 y la duración de las fijaciones con 0.033.

La diferencia entre ambas observaciones se debe a que una sola característica pupilar tuvo una importancia muy alta, mientras que las bandas gamma y beta se basaron en la contribución de múltiples características del EEG. Por esta razón, la suma de un grupo no debe interpretarse como si cada característica de ese grupo fuera más importante por separado. Tampoco significa que estas variables sean una causa directa de la emoción, sino que el modelo las utilizó más para realizar sus divisiones.

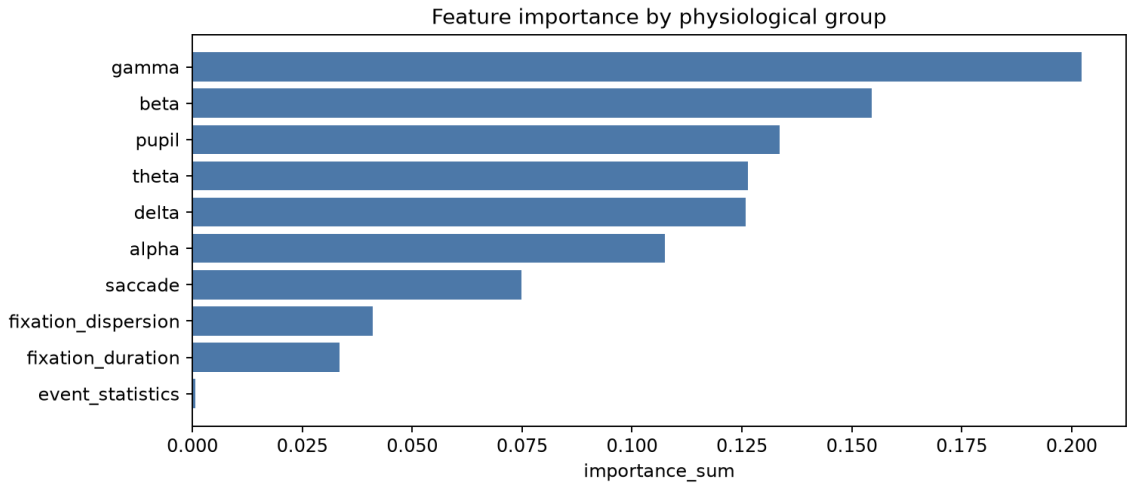


Figura 8. Importancia acumulada de las características agrupadas por banda de EEG y por tipo de variable ocular.

3.9 Relación de los resultados con estudios anteriores

De manera descriptiva, el reconocimiento emocional fue menor durante la privación del sueño que durante la recuperación y el sueño normal. El F1 macro fue de 0.468 para privación, 0.581 para recuperación y 0.591

para sueño normal. Este comportamiento fue congruente con lo reportado por Li et al. (2025), quienes encontraron una disminución significativa del reconocimiento emocional durante la privación y resultados similares durante la recuperación y en el sueño normal. También coincide con estudios independientes en los que la pérdida de sueño redujo el reconocimiento de la felicidad y la tristeza, mientras que el sueño de recuperación permitió recuperar el desempeño (Killgore et al., 2017). Sin embargo, en el presente trabajo, la comparación entre condiciones fue descriptiva, ya que los modelos y las representaciones seleccionados no fueron idénticos.

La mejora obtenida al combinar EEG y seguimiento ocular también fue consistente con los hallazgos de estudios previos. En las 20 comparaciones realizadas para C1, agregar las características oculares aumentó el F1 macro frente al uso exclusivo del EEG. Lu et al. (2015) y Zheng et al. (2019) también encontraron que la fusión de ambas modalidades supera sus resultados individuales. Esto puede explicarse porque el EEG registra cambios en la actividad cerebral, mientras que el seguimiento ocular proporciona información adicional sobre la activación pupilar, las fijaciones, las sacadas y la atención visual.

En el análisis de características, gamma y beta presentaron la mayor importancia acumulada en el EEG, mientras que el diámetro pupilar fue el parámetro ocular más relevante. Estos resultados fueron consistentes con estudios que identificaron una mayor cantidad de información discriminativa para el reconocimiento emocional en las bandas beta y gamma (Zheng y Lu, 2015). Asimismo, se ha reportado que los cambios en el diámetro pupilar se relacionan con la activación emocional y con la actividad del sistema nervioso autónomo (Bradley et al., 2008). No obstante, estas variables no deben considerarse marcadores clínicos ni causas directas de las emociones, ya que también pueden verse afectadas por la iluminación, la atención, la fatiga y las diferencias entre los participantes.

Conclusiones

En este trabajo se analizó el reconocimiento de emociones bajo tres condiciones de sueño, mediante características del EEG y del seguimiento ocular. Los resultados mostraron que fue posible reconocer la neutralidad, la tristeza, el miedo y la felicidad en sujetos que no participaron en el entrenamiento. De esta manera, las señales fisiológicas sí contienen información relacionada con la respuesta emocional, aunque el desempeño aún presentó errores en algunas de ellas.

La combinación de EEG y Eye fue más útil que el uso exclusivo de EEG para el reconocimiento emocional. Esta mejora se observó en los cuatro problemas de C1 y con los distintos clasificadores evaluados. Esto muestra que ambas modalidades aportaron información complementaria, ya que el EEG registró la actividad cerebral y las características oculares proporcionaron información sobre la respuesta pupilar, las fijaciones y las sacadas.

El mejor modelo seleccionado fue Random Forest para C1-NS, utilizando clips de sueño normal divididos en cuatro bloques y reducidos a 1,000 características. Este modelo obtuvo un accuracy de 0.594 y un F1 macro de 0.591 en el conjunto de prueba. También se obtuvo un resultado cercano durante la recuperación del sueño, mientras que, en la privación, el modelo seleccionado mostró un desempeño menor. Esto permite observar una diferencia entre las condiciones, pero no permite asegurar que la privación del sueño haya causado por sí sola esta disminución.

La división de cada clip en cuatro bloques permitió conservar más información sobre los cambios ocurridos durante el estímulo. Esta forma de representación fue útil para el sueño normal y la recuperación, pero no mejoró de manera general los cuatro problemas de reconocimiento emocional. Por esta razón, aumentar el número de características no garantiza, por sí solo, un mejor clasificador. La selección de características fue necesaria para reducir la información redundante y evitar que las 7,200 variables entraran directamente al modelo.

En el enfoque C2 se encontró que las condiciones de privación, recuperación y sueño normal podían distinguirse mejor que el azar cuando se mantenía fija una emoción. Los mejores resultados de este enfoque se obtuvieron con los clips de felicidad y de tristeza. Sin embargo, los valores fueron moderados y la recuperación del sueño presentó varias confusiones con las demás condiciones. Esto indica que hay información relacionada con el sueño en las respuestas fisiológicas, pero no fue suficiente para distinguir con precisión entre las tres condiciones.

Las características individuales de mayor importancia estuvieron relacionadas principalmente con el diámetro pupilar, la amplitud de las sacadas y de las fijaciones. Al agrupar las variables, las bandas gamma y beta

presentaron la mayor importancia en el EEG, mientras que el diámetro pupilar fue el grupo ocular con mayor aporte. Estos resultados respaldan el uso conjunto de EEG y seguimiento ocular, pero las importancias representan el uso que hizo el modelo de las variables y no una relación de causa y efecto.

Random Forest apareció entre los mejores modelos porque pudo trabajar con relaciones no lineales y con combinaciones de características de EEG y de Eye.

En general, los resultados obtenidos muestran que las condiciones de sueño se asocian con cambios en la forma en que las emociones pueden reconocerse mediante señales fisiológicas. El proyecto todavía no demuestra un impacto causal ni clínico del sueño sobre las emociones. Lo que sí muestra es que el desempeño de clasificación y las características utilizadas por los modelos varían entre la privación, la recuperación y el sueño normal.

Como trabajo futuro, se podría dejar probar C1-NS con más de 1,000 características, ya que fue el mejor resultado, pero también fue el máximo de características con las que se entrenó el Random Forest de 7,200 características obtenidas al separar en 4 bloques temporales por clip, ya que todo indica que a más "detalle" de características, mejor el resultado.

También, como trabajo futuro, podría probar modelos de IA más sofisticados, como un MLP que entienda mejor las relaciones no lineales.

Los resultados obtenidos son consistentes con la evidencia de que la privación del sueño modifica el procesamiento de las emociones y de que el sueño de recuperación puede reducir parte de estas diferencias. Además, la combinación de EEG y seguimiento ocular permitió identificar información complementaria relacionada tanto con la emoción como con el estado de sueño.

Bibliografía

Almanza-Conejo, O., Almanza-Ojeda, D. L., Contreras-Hernández, J. L., & Ibarra-Manzano, M. A. (2023). Emotion recognition in EEG signals using the continuous wavelet transform and CNNs. *Neural Computing and Applications, 35*(2), 1409–1422. https://doi.org/10.1007/s00521-022-07843-9

Beattie, L., Kyle, S. D., Espie, C. A., & Biello, S. M. (2015). Social interactions, emotion and sleep: A systematic review and research agenda. *Sleep Medicine Reviews, 24*, 83–100. https://doi.org/10.1016/j.smrv.2014.12.005

Bradley, M. M., Miccoli, L., Escrig, M. A., & Lang, P. J. (2008). The pupil as a measure of emotional arousal and autonomic activation. Psychophysiology, 45(4), 602–607. https://doi.org/10.1111/j.1469-8986.2008.00654.x

Killgore, W. D. S., Balkin, T. J., Yarnell, A. M., & Capaldi, V. F., II. (2017). Sleep deprivation impairs recognition of specific emotions. *Neurobiology of Sleep and Circadian Rhythms, 3*, 10–16. https://doi.org/10.1016/j.nbscr.2017.01.001

Li, Z., Tao, L.-Y., Ma, R.-X., Zheng, W.-L., & Lu, B.-L. (2025). Investigating the effects of sleep conditions on emotion responses with EEG signals and eye movements. *IEEE Transactions on Affective Computing, 16*(4), 3198–3214. https://doi.org/10.1109/TAFFC.2025.3572504

Lu, Y., Zheng, W.-L., Li, B., & Lu, B.-L. (2015). Combining eye movements and EEG to enhance emotion recognition. In *Proceedings of the 24th International Joint Conference on Artificial Intelligence* (pp. 1170–1176). AAAI Press.

Zheng, W.-L., Liu, W., Lu, Y., Lu, B.-L., & Cichocki, A. (2019). EmotionMeter: A multimodal framework for recognizing human emotions. *IEEE Transactions on Cybernetics, 49*(3), 1110–1122. https://doi.org/10.1109/TCYB.2018.2797176

Zheng, W.-L., & Lu, B.-L. (2015). Investigating critical frequency bands and channels for EEG-based emotion recognition with deep neural networks. *IEEE Transactions on Autonomous Mental Development, 7(3), 162–175.* https://doi.org/10.1109/TAMD.2015.2431497