



Aproximación a la clasificación de la atención basada en optimización por enjambre de partículas con pruebas de seguimiento ocular

Medina Magdaleno Guillermo Ernesto, Aceves Fernández Marco Antonio,
Pedraza Ortega Jesús Carlos

Facultad de Ingeniería, Universidad Autónoma de Querétaro, 76010, Querétaro, México.
marco.aceves@uaq.mx

Resumen

La clasificación de la atención ha sido ampliamente estudiada en la última década, con metodologías y propuestas para varios propósitos tales como la detección temprana del desorden del espectro autista, trastorno de déficit de atención e hiperactividad (TDAH) o sólo para tener una herramienta confiable para determinar si un sujeto está atento o no. En este trabajo, una metodología para la clasificación de la atención visual basada en optimización por enjambre de partículas utilizando datos obtenidos con seguidor ocular e propuesta. Primero, se obtuvieron los datos por medio de un conjunto de pruebas visuales aplicadas a un número determinado de sujetos adultos mientras la posición de sus miradas era registrada por medio de un seguidor ocular. Después, los datos fueron procesados para extraer las características deseadas para construir la base de datos final. Para optimizar el modelo, se utilizó un algoritmo de optimización por enjambre de partículas en conjunto con K-Means para generar el número óptimo de grupos a utilizar para la clasificación con KNN. Finalmente, se evaluó el rendimiento y se comparó con otros trabajos del estado del arte. La metodología propuesta alcanzó una exactitud del 97.78% sin el uso de equipo caro o invasivo. Por lo tanto, una herramienta confiable y cómoda para clasificar la atención visual fue lograda con la metodología propuesta.

Palabras clave: Atención visual, Optimización por enjambre de partículas, PSO, Clasificación

Abstract

Attention classification has been widely studied over the last decade, with methodologies and proposals for various purposes such as the early detection of autistic spectrum disorder, Attention Deficit Hyperactivity Disorder (ADHD) or just to have a reliable tool to determine whether a subject is being attentive or not. In this work, a methodology for visual attention classification based on particle swarm optimization using eye tracker data is proposed. Firstly, the data is obtained through a series of visual tests applied to a certain number of adult subjects while the eye coordinates are acquired by an eye tracker. Then, the data is processed to extract the desired features to build the final dataset. To optimize the model, a particle swarm optimization with K-Means algorithm is performed to generate the optimum groups to be used for classification with KNN. Finally, the performance evaluation and comparison with other works from the state of the art is carried out. The proposed methodology reached an accuracy of 97.78% without the use of expensive or cumbersome equipment.

Keywords: visual attention, particle swarm optimization, PSO, classification



1. Introducción

La atención visual es un fenómeno que ha sido estudiado desde el siglo pasado. Los primeros estudios estaban limitados tecnológicamente a simple observación o introspección. Von Helmholtz observó la tendencia natural de la atención visual a desviarse o redirigirse a cosas nuevas, estaba principalmente enfocado con movimientos oculares a lugares especiales o al “dónde” de la atención visual [1]. En los años 80’s, Posner señaló que la atención visual podía ser comparada con un faro o una lámpara, haciendo referencia al espacio limitado al que se enfocaba en el centro. Otros autores como Eriksen y Yeh hacen la misma comparación, pero lo llaman un “zoom” u otros autores como Downing y Pinker que hacen la comparación con un gradiente Gaussiano [2].

Durante la última década, metodologías y propuestas para clasificar la atención con varios fines ha sido desarrollada, desde la detección temprana del trastorno del espectro autista [3], déficit de atención e hiperactividad [4], o simplemente para desarrollar una herramienta para determinar si un sujeto está atento o no [5].

Sin embargo, algunos de estos métodos pueden ser muy invasivos, como la aplicación de electroencefalografía para determinar niveles de atención [6] o clasificar TDAH en donde existen señales ruidosas [24].

Utilizando un seguidor ocular como método no invasivo puede ser un reto, sin embargo, es una opción viable en términos de practicidad y costo, tomando ventaja de los datos valiosos que se pueden obtener a través del estudio de la mirada y haciendo uso de la información adecuadamente [7].

Existen estudios tanto recientes como de la década pasada referentes a tecnologías de seguimiento ocular o algoritmos basados en inteligencia artificial para clasificar la atención o trastorno del espectro autista utilizando técnicas de aprendizaje de máquina tales como árboles aleatorios, bosques aleatorios o algoritmos genéticos con máquinas de soporte vectorial [4-5-25].

Así mismo, estudios de la década pasada han demostrado que las metodologías basadas en inteligencia de enjambre usadas para la optimización, extracción de características o simplemente para mejorar el rendimiento general [8-12] dan resultados satisfactorios incluso cuando se comparan con metodologías basadas en aprendizaje de máquina estándar [13], lo que sugiere que utilizar una metodología basada en inteligencia de enjambre puede traer buenos resultados para el problema de la clasificación con datos obtenidos con seguidor ocular.

En este trabajo, se propone una metodología basada en inteligencia de enjambre para clasificar niveles de atención visual con datos obtenidos por medio de un seguidor ocular.

La estructura de este artículo es la siguiente, en la sección II se presentará el trasfondo teórico relativo a la atención visual, seguimiento ocular e inteligencia de enjambre; en la sección III se incluyen los materiales y métodos; en la sección IV se presentan los resultados y finalmente en la sección V se finaliza con una conclusión.

2. Trasfondo teórico

2.1 Atención Visual

En el contexto de la atención visual, existen dos funciones principales el ojo humano: rastreo y fijación. La fijación ocurre cuando el ojo está fijo a un objetivo visual en particular. Esto permite a los ojos maximizar el enfoque en el objeto. El rastreo es la habilidad de mantener el enfoque en un objeto



incluso cuando este se mueve. Esto es importante ya que casi todos los objetos en el mundo real están en movimiento. Sin la habilidad para rastrear, sería muy difícil percibir cualquier cosa. El mecanismo de atención visual debe tener al menos estos componentes principales [14]:

- La selección de una región de interés en el campo visual.
- La selección de las dimensiones características y valores de interés.
- El control de flujo de información que fluye a través de la red neuronal que conforma el sistema visual.
- La habilidad para saltar de una región de interés a otra en un tiempo determinado.

2.2 Seguimiento Ocular

El dispositivo utilizado para medir el movimiento ocular es llamado seguidor ocular. Generalmente, existen dos tipos de técnicas de seguimiento ocular, una que mide la posición del ojo relativa a la cabeza, y otra que mide la orientación del ojo en un espacio o punto de consideración [14]. Actualmente, la tecnología del seguimiento ocular tiene aplicaciones que van desde los video juegos y realidad virtual, hasta la publicidad web e investigación [15].

2.3 Inteligencia de Enjambre

Los algoritmos de inteligencia de enjambre son algoritmos meta-heurísticos que imitan el comportamiento social de colonias de insectos, donde cada agente representa una potencial solución a un problema dado. Durante cada ciclo de solución, cambian sus posiciones y se mueven dentro de un dominio con el objetivo de encontrar una mejor solución [16].

2.4 Optimización por Enjambre de Partículas

La optimización por enjambre de partículas o PSO por sus siglas en inglés es un algoritmo de optimización que simula el comportamiento de parvadas de aves. Esto funciona inicializando un conjunto de partículas (en este contexto, un ave es una “partícula”, la cual también es una potencial solución a un problema) aleatoriamente sobre un espacio de búsqueda determinado. El enjambre converge hacia posición global óptima a una cierta velocidad, con cada iteración, la velocidad de cada partícula cambia basada en la inercia, la mejor posición alcanzada por la partícula y la mejor posición de todas las partículas en estado actual, después, basado en la velocidad la posición para cada partícula cambia. La posición y velocidad de la i -ésima partícula en la i -ésima iteración es mostrada en el vector $X = (x_{i1}^t, x_{i2}^t, x_{in}^t)$ y $V = (v_{i1}^t, v_{i2}^t, v_{in}^t)$ la mejor posición personal de un partícula en el vector $P = (p_{i1}^t, p_{i2}^t, p_{in}^t)$ y finalmente el mejor global con el vector $G = (g_{i1}^t, g_{i2}^t, g_{in}^t)$. Finalmente, con cada iteración, la velocidad y posición de una partícula se actualiza usando las ecuaciones 1 y 2 como se muestra [17]:

$$V_i^{(t)} = \omega * V_i^{(t-1)} + c_1 * r_1 (P_i - X_i^{(t-1)}) + c_2 * r_2 (G_i - X_i^{(t-1)}) \quad (1)$$

$$X_i^{(t)} = X_i^{(t-1)} + V_i^{(t)} \quad (2)$$

Donde ω es conocido como el peso de inercia y controla el impacto de velocidades previas de la partícula en la velocidad actual, r_1 y r_2 son dos variables en el rango de $[0, 1]$, c_1 y c_2 son constantes de aceleración y son valores positivos que controlan el tamaño del paso entre iteraciones.

2.5 Algoritmo PSO-K Means

El algoritmo utilizado en este trabajo es un híbrido entre PSO y K-Means para agrupación de datos. Este algoritmo consiste en alimentar el enjambre inicial con K-Means primero, donde K-Means es concluido cuando se cumplen con ciertos criterios, el número de iteraciones se alcanza, o cuando el



promedio de cambio en la posición del centroide es menor a un parámetro establecido. El resultado después es utilizado como una de las partículas, mientras que el resto se generan aleatoriamente [18].

2.6 Agrupamiento y K-Means

Las técnicas de agrupamiento se refieren a organizar un cierto grupo de objetos que comparten características similares, está clasificado bajo los métodos de aprendizaje automático no supervisados, lo que significa que no existe un entrenamiento previo del cual aprender. La idea principal en el algoritmo de K-Means es definir grupos o cúmulos de datos. Primero, se selecciona un número de cúmulos requeridos, cada uno de los cúmulos contiene un centroide, un punto donde la distancia de un objeto será calculada. Los cúmulos se definen por un proceso iterativo en las distancias de los objetos los cuales están más cerca del centroide. Para conocer qué centroide es asignado a qué objeto, el algoritmo utiliza una medida de distancia Euclídeana. La suma de los cuadrados es calculada con la raíz de la distancia Euclídeana para cada centroide de cada cúmulo, el que tenga un valor menor es el cluster al cual cierto objeto será asignado [19]. El algoritmo de K-Means se puede resumir de la siguiente manera [17].

- Inicializar aleatoriamente el centroide K donde $Z = (z_1, z_2, z_k)$.
- Hasta que se cumpla el criterio de paro, asignar un centroide a cada dato que está más cerca de él, la distancia del punto dado y_p al centroide en un espacio d-dimensional está dado por: $D(y_p, z_j) = \sqrt{\sum_{i=1}^d (y_{pi} - z_{ji})^2}$ (3)
- Recalcular los centroides, el centroide para el cúmulo j está definido por: $z_j = \frac{1}{n_j} \sum_{y_p \in c_j} y_p$ (4) dónde c_j es un subconjunto de datos pertenecientes al j-ésimo cúmulo, y n_j es el número de datos en dicho cúmulo.
- El algoritmo entonces termina cuando el número de iteraciones alcanza cierto parámetro, cuando no existe cambio en la membresía del cúmulo, o cuando dicha membresía es despreciable.

2.7 Clasificador KNN

El clasificador por k vecinos más cercanos o KNN por sus siglas en inglés, es un algoritmo de clasificación utilizado para clasificar datos no etiquetados basado en la etiqueta de las observaciones más cercanas a un punto dado. Existen dos parámetros importantes que tener en cuenta cuando se usa KNN, uno es la distancia calculada entre una observación y sus vecinos más cercanos, generalmente siendo distancia Euclídeana como se muestra:

$$D(p, q) = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} \quad (5)$$

Donde p y q son observaciones a ser comparados con n características. Y el otro parámetro importante es el parámetro “K”, el cual determina cuántos vecinos con una etiqueta dada son necesarios para clasificar la observación objetivo [20].

3. Materiales y métodos

3.1 Adquisición de datos y construcción de base de datos

Para el modelo propuesto, los datos fueron obtenidos a través de una serie de pruebas visuales que se aplicaron a 41 sujetos adultos tanto hombres como mujeres, las coordenadas de sus miradas fueron registradas utilizando un seguidor ocular de la marca “Eye Tribe” modelo ET1000 (Figura 1) con una frecuencia de muestreo de 60Hz. Fueron un total de 11 pruebas visuales las que fueron aplicadas a cada sujeto.



Figura 1. Seguidor ocular Eye Tribe ET1000.

El experimento consistió de 6 plantillas D-48 de pruebas de dominó y 5 pruebas de cubos desplegados, las cuales se pueden observar en las figuras 2 y 3 respectivamente. En estas pruebas, el sujeto debe observar el patrón presentado y elegir la respuesta correcta.




Figura 2. Prueba D-48.




Figura 3. Prueba de cubo desplegado.

Una vez que las pruebas fueron realizadas por los sujetos, las coordenadas del registro del seguidor ocular fueron obtenidas como se muestra en la tabla 1 la cual muestra un registro de tiempo, sí la mirada es una fijación o no y posiciones en X y Y promedio de la mirada. De los datos de la tabla 1 se extrajeron las características deseadas utilizando imágenes arrojadas por el seguidor ocular las cuales contienen puntos de mirada (Figura 4). Una de las características a extraer fue el porcentaje de puntos de mirada dentro de un área de interés o AOI por sus siglas en inglés, para cada una de las pruebas visuales. Otra característica fue el porcentaje de fijaciones por cada prueba visual, fijaciones siendo un movimiento ocular donde la mirada está fija en un punto por un tiempo determinado [21]. Y finalmente, las respuestas correctas para cada prueba visual. Esto se muestra en la figura 5.

Tabla 1. Datos en crudo obtenidos con seguidor ocular.

	Timestamp	fix	avgx	avgy
108	42:39.4	False	991.9171	713.4952
109	42:39.5	False	0	0
110	42:40.0	False	493.5139	525.2659
111	42:40.2	False	303.2414	411.4729
112	42:40.2	False	300.7155	411.318
113	42:40.3	False	245.6798	404.1431
114	42:40.5	True	262.7594	453.4751




Figura 4. Imagen de datos en crudo obtenida con seguidor ocular mostrando puntos de mirada.




Figura 5. Áreas de interés definidas.

3.2 Implementación del modelo.

Los niveles de la implementación del modelo fueron las siguientes (Figura 6): Pre-procesamiento, donde las columnas inválidas se eliminaron. Normalización de los datos y finalmente reducción de dimensiones utilizando análisis de componentes principales o PCA por sus siglas en inglés. El siguiente nivel corresponde a la generación de etiquetas y agrupamiento, donde se aplica el método del codo para determinar el número óptimo de cúmulos para nuestros datos, la fórmula se muestra en la ecuación 6.

$$J = \sum_{i=1}^k \sum_{x \in C_i} |x - C_i|^2 \quad (6)$$

Dónde J es una función de costo, x es el elemento del cúmulo C_i y k es el número de cúmulos. En este caso, se encontró que el número óptimo de cúmulos fue de 3 como se muestra en la figura 7, en donde el eje vertical representa el error o la suma de cuadrados dentro del cúmulo (WCSS por sus siglas en inglés) y el eje horizontal representa el número de cúmulos generado. Se observa que a mayor número de cúmulos es menor el error, sin embargo, a partir del “codo” que se forma en la gráfica empieza a ser casi despreciable el cambio.

Seguido, el algoritmo de PSO-K Means es calculado para generar los cúmulos para que el algoritmo de clasificación pudiera ser ejecutado con KNN. Finalmente, la evaluación del modelo toma lugar utilizando una validación cruzada K-fold. Se realizaron comparación con trabajos similares del estado del arte para evaluar más a fondo el rendimiento del modelo propuesto.

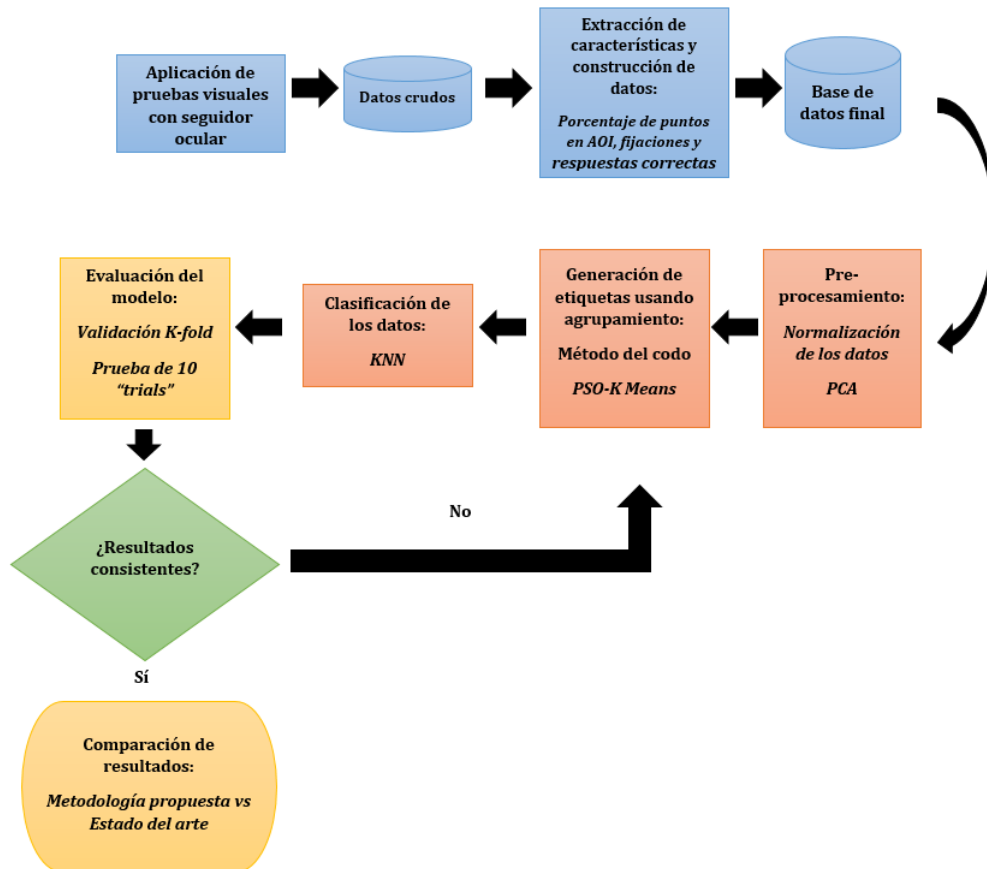


Figura 6. Diagrama de flujo de la metodología propuesta.




Figura 7. Definición del número de cúmulos utilizando el método del codo.

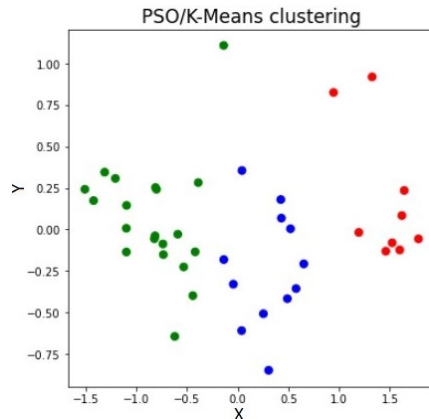


Figura 8. Cúmulo generados con PSO/K Means.

4. Resultados

En esta sección, se presentan los resultados del modelo propuesto, es importante mencionar que las pruebas fueron aplicadas a 41 sujetos de varias edades tanto hombres como mujeres. La clasificación se realizó con un clasificador KNN utilizando un parámetro K igual a 7. Una vez que la clasificación de las tres etiquetas generadas se completó, el modelo fue evaluado utilizando una validación cruzada K fold con un valor de K igual a 5, asegurando así que el 20% de los datos se utilizaran para prueba y el 80% para entrenamiento para cada partición. Después de la implementación de la validación cruzada, la exactitud promedio se obtuvo. Finalmente, los resultados son presentados en comparación con trabajos similares del estado del arte para tener un punto de referencia del rendimiento de la metodología propuesta.

En la siguiente tabla se muestran los resultados de la metodología propuesta. Las métricas fueron obtenidas con validación cruzada y el promedio de cada métrica es presentado, así como también la exactitud promedio obtenida. Las métricas utilizadas fueron precisión, sensibilidad y puntuación F1 como se muestra en la tabla 2.

Tabla 2. Resultados de la metodología propuesta.

Valor	Valor promedio para K-fold con K=5		
	Precisión	Sensibilidad	F1
Promedio Macro	98.67%	97.78%	97.92%
Varianza	0.07%	0.19%	0.17%
Promedio ponderado	98.22%	97.78%	97.68%
Varianza	0.08%	0.20%	0.18%
Exactitud = 97.78%			
Varianza = 0.20%			

La tabla 2 muestra los resultados promedio de la metodología propuesta evaluados con una validación cruzada k-fold. Para verificar la consistencia de los resultados, se realizó una prueba adicional que consistió en 10 iteraciones en donde los conjuntos de entrenamiento y prueba se aleatorizaban con cada iteración. En la figura 9, 10 y en la tabla 3 se muestran los resultados de estas pruebas, en donde se utilizaron las mismas métricas que en la validación cruzada.

Tabla 3. Resultados de la metodología propuesta por 10 iteraciones.

Value	Valores promedio por 10 iteraciones		
	Precisión	Sensibilidad	F1
Promedio Macro	96.38%	97.67%	96.40%
Varianza	34.03%	14.43%	31.49%
Promedio ponderado	95.79%	94.44%	94.25%
Varianza	48.55%	80.24%	85.80%
Exactitud = 96.67%			
Varianza = 25.92%			

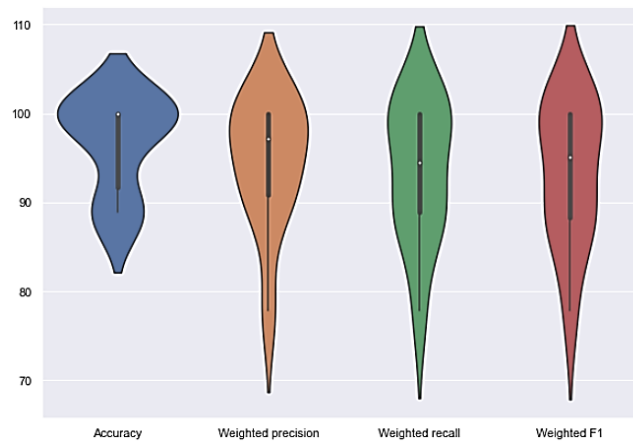


Figura 9. Valores ponderados para 10 iteraciones.

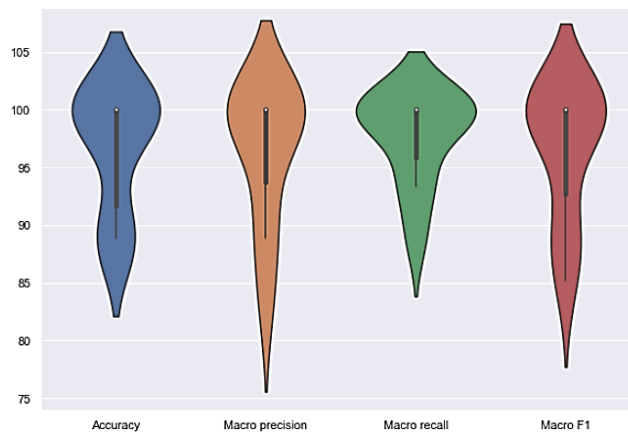


Figura 10. Valores macro para 10 iteraciones.

La exactitud promedio fue de 96.67% para este caso, ligeramente inferior que en la validación cruzada, pero manteniéndose por encima del 95%. El resto de las métricas también fueron ligeramente distintas a las de la prueba anterior.



En trabajos previos del estado del arte, los sensores utilizados para la adquisición de datos para explorar estados de atención van desde electroencefalogramas hasta seguidores oculares. En la siguiente tabla se comparan los resultados de trabajos previos con el de la metodología propuesta. Dicha metodología supera en rendimiento a los trabajos previos presentados con una exactitud del 97.78% como se muestra en la tabla 3.

Tabla 4. Comparación de resultados con el estado del arte.

Author	Comparación		
	Exactitud	Sensores	Método propuesto
De Silva <i>et al.</i> (2019)	85.31%	Seguidor ocular	Bosque Aleatorio
Alirezai <i>et al.</i> (2017)	92.8%	EEG	C-SVM
Chen <i>et al.</i> (2017)	93.1%	Seguidor ocular	GA-SVM
Trabajo propuesto	97.78%	Seguidor ocular	KMeans/PSO-KNN

5. Conclusiones

En el presente trabajo, se propuso y desarrolló una metodología para clasificar niveles de atención por medio de datos obtenidos por medio de un seguidor ocular relativamente de bajo costo que fuera capaz de realizar la tarea de manera confiable, eficiente y repetible sin la necesidad de equipo costoso o invasivo para el sujeto que toma las pruebas. Con dicha metodología, se logró un rendimiento del 97.78% al mismo tiempo que se eliminó la necesidad de equipo muy sofisticado que puede no estar al alcance de muchas personas. La varianza del rendimiento no superó el 0.20%. los resultados obtenidos y mostrados en este trabajo probaron ser consistentes a través de pruebas realizadas e incluso superaron en rendimiento a trabajos anteriores del estado del arte. Esto se logró gracias a una metodología basada en PSO que se utilizó para optimizar la generación de etiquetas y agrupamiento crucial para la labor de clasificación. Al final, se logró una metodología consistente y exacta para clasificar niveles de atención sin la necesidad de equipo costoso o incómodo que no requerirá que el paciente utilice ningún tipo de accesorio al momento de tomar las pruebas visuales, lo que vuelve a nuestro sistema fácil de operar tanto para profesionales como para los pacientes.

Referencias

- [1] A. T. Duchowski, *Eye tracking methodology*. Cham: Springer International Publishing, 2017.
- [2] M. Carrasco, "Visual attention: the past 25 years," *Vision Res.*, vol. 51, no. 13, pp. 1484–1525, 2011.
- [3] Mestas Hernández, L., Gordillo León, F., Castillo Parra, G., & Escotto Córdova, E., "Diagnóstico y tratamiento de los trastornos del espectro autista: Eye-tracking e integración sensorial," *EduPsykhé: Revista de Psicología y Psicopedagogía*, vol. 1, no. 15, pp. 93–110, 2016.
- [4] S. De Silva *et al.*, "A rule-based system for ADHD identification using eye movement data," in 2019 Moratuwa Engineering Research Conference (MERCon), 2019.
- [5] O. T. C. Chen, P. C. Chen, and Y. T. Tsai, "Attention estimation system via smart glasses," in 2017 IEEE Conference on Computational Intelligence in Bioinformatics and Computational Biology (CIBCB), 2017.
- [6] C.-M. Chen, J. Y. Wang, and C. M. Yu, "Assessing the attention levels of students by using a novel attention aware system based on brainwave signals: Novel attention aware system based on brainwave signals," *Br. J. Educ. Technol.*, vol. 48, no. 2, pp. 348–369, 2017.



- [7] R. J. Leigh and D. S. Zee, *Neurology of eye movements*. F. A. Davis Company, 1983.
- [8] V. Agrawal and S. Chandra, "Feature selection using Artificial Bee Colony algorithm for medical image classification," in *2015 Eighth International Conference on Contemporary Computing (IC3)*, 2015.
- [9] W. C. Kao, C.-Y. Lee, C. Y. Lin, T. Y. Su, B. Y. Ke, and C. Y. Liao, "Gaze tracking with particle swarm optimization," in *2015 International Symposium on Consumer Electronics (ISCE)*, 2015.
- [10] B. Ordóñez De León, M. A. Aceves Fernandez, S. M. Fernandez Fraga, J. M. Ramos Arreguín, and E. Gorrostieta Hurtado, "An improved particle swarm optimization (PSO): method to enhance modeling of airborne particulate matter (PM10)," *Evol. syst.*, 2019.
- [11] S. M. Fernandez Fraga, M. A. Aceves Fernandez, J. C. Pedraza Ortega, S. Tovar Arriaga, "Feature Extraction of EEG Signal upon BCI Systems Based on Steady-State Visual Evoked Potentials Using the Ant Colony Optimization Algorithm", *Discrete Dynamics in Nature and Society*, vol. 2018, Article ID 2143873, 19 pages, 2018. <https://doi.org/10.1155/2018/2143873>.
- [12] Martínez Zeron, E., Aceves Fernandez, M. A., Gorrostieta Hurtado, E., Sotomayor Olmedo, A., & Ramos Arreguín, J. M. (2014). Method to improve airborne pollution forecasting by using ant colony optimization and neuro-fuzzy algorithms. *International Journal of Intelligence Science*, 4(04), 81.S. P. Bingulac, "On the compatibility of adaptive controllers (Published Conference Proceedings style)," in *Proc. 4th Annu. Allerton Conf. Circuits and Systems Theory*, New York, 1994, pp. 8–16.
- [13] M. Etehadi Abari, "A Novel Eye Gaze Estimation Method Using Ant Colony Optimizer," *Journal of Computer & Robotics*, vol. 1, no. 12, pp. 113–122, 2019.
- [14] F. Francis and A. Suresh, "A cognitive model for analyzing visual attention using ocular movements," in *2017 International Conference on Energy, Communication, Data Analytics and Soft Computing (ICECDS)*, 2017.
- [15] A. Kar and P. Corcoran, "A review and analysis of eye-gaze estimation systems, algorithms and performance evaluation methods in consumer platforms," *IEEE Access*, vol. 5, pp. 16495–16519, 2017.
- [16] M. P. Saka, E. Doğan, and I. Aydogdu, "Analysis of swarm intelligence-based algorithms for constrained optimization," in *Swarm Intelligence and Bio-Inspired Computation*, Elsevier, 2013, pp. 25–48.
- [17] A. Ahmadyfard and H. Modares, "Combining PSO and k-means to enhance data clustering," in *2008 International Symposium on Telecommunications*, 2008.
- [18] D. W. van der Merwe and A. P. Engelbrecht, "Data clustering using particle swarm optimization," in *The 2003 Congress on Evolutionary Computation*, 2003. CEC '03, 2004.
- [19] J. Bell, *Machine learning: Hands-on for developers and technical professionals*, 2nd ed. Nashville, TN: John Wiley & Sons, 2020.
- [20] Z. Zhang, "Introduction to machine learning: k-nearest neighbors," *Ann. Transl. Med.*, vol. 4, no. 11, p. 218, 2016.
- [21] L. Larsson, M. Nyström, R. Andersson, and M. Stridh, "Detection of fixations and smooth pursuit movements in high-speed eye-tracking data," *Biomed. Signal Process. Control*, vol. 18, pp. 145–152, 2015.
- [22] Alirezaei, M., & Sardouie, S. H., "Detection of human attention using EEG signals," in *24th National and 2nd International Iranian Conference on Biomedical Engineering (ICBME)*, 2017, pp. 1–5.
- [23] F. Liu and Y. Deng, "Determine the number of unknown targets in open world based on elbow method," *IEEE Trans. Fuzzy Syst.*, vol. 29, no. 5, pp. 986–995, 2021.
- [24] M. A. Aceves Fernandez, "Methodology proposal of ADHD classification of children based on cross recurrence plots," *Nonlinear Dyn.*, vol. 104, no. 2, pp. 1491–1505, 2021.
- [25] Z. Zhao, H. Tang, X. Zhang, X. Qu, X. Hu, and J. Lu, "Classification of children with autism and typical development using eye-tracking data from face-to-face conversations: Machine learning model development and performance evaluation," *J. Med. Internet Res.*, vol. 23, no. 8, p. e29328, 2021.



Autores

Medina Magdalena Guillermo Ernesto. Obtuvo su licenciatura en ingeniería mecánica en el Instituto Tecnológico de Hermosillo. Actualmente se encuentra en proceso de obtener su grado de maestro en ciencias en inteligencia artificial por la Universidad Autónoma de Querétaro.

Aceves Fernández Marco Antonio. Obtuvo su licenciatura en ingeniería telemática en la Universidad de Colima, México. Obtuvo su grado de maestría y doctorado en la Universidad de Liverpool, Inglaterra, en el campo de sistemas inteligentes. Es profesor de tiempo completo en la facultad de ingeniería de la Universidad Autónoma de Querétaro, México. Es miembro del sistema nacional de investigadores (SNI) desde 2009. También es presidente honorario en la Asociación Mexicana de Sistemas Embebidos (AMESE). Sus intereses de investigación incluyen sistemas inteligentes y embebidos.

Pedraza Ortega Jesús Carlos. Obtuvo su licenciatura en ingeniería electrónica en el Instituto Tecnológico de Celaya, México. Su maestría en ciencias en ingeniería electrónica en FIMEE Universidad de Guanajuato y su doctorado en ingeniería mecánica en la Universidad de Tsukuba en Japón. Es profesor de tiempo completo en la facultad de ingeniería de la Universidad Autónoma de Querétaro, México. Es miembro del sistema nacional de investigadores (SNI) desde 2004. Desde 2007 fue aceptado como miembro de la Academia Mexicana de Ciencia (AMC). Sus intereses de investigación incluyen visión por máquina, reconstrucción 3D, procesamiento de imágenes, aprendizaje profundo y aprendizaje de máquina.