*VISUAL REVIEW* | Vol. 18, No. 8, 2026 | ISSN 2695-9631

*International Visual Culture Review / Revista Internacional de Cultura Visual*

https://doi.org/ρπ8φςρφρ7ÒÅÖÖÉÓÕÁÌ8Öρψ8φτψψ

# EYE TRACKING PREDICTIVO EN REDES SOCIALES: ANÁLISIS COMPARATIVO DE PLATAFORMAS IA

Precisión, tecnología y aplicabilidad en social media

Predictive *Eye Tracking* in Social Media: Comparative Analysis of AI Platforms Accuracy, Technology, and Applicability in Social Media

M. EUGENIA LAURECKIS MOLLA [1]
mariaeugenia.laureckis@esic.edu
ÀLEX VALLEJO-BLANXART [1]
alex-vallejo@esic.edu
[1]ESIC Business & Marketing School, España

**PALABRAS CLAVE**

*Eye tracking predictivo*
*Atención visual*
*Inteligencia artificial*
*Redes sociales*
*Modelos de saliencia*
*Neuromarketing*
*Validación con benchmark*

**RESUMEN**

*La atención visual es un recurso escaso en redes sociales, caracterizadas por saturación de contenidos e interacciones rápidas. Las herramientas de eye tracking predictivo basadas en inteligencia artificial prometen análisis escalables, aunque su validez científica y aplicabilidad práctica resultan heterogéneas. Este estudio evalúa comparativamente diez plataformas comerciales mediante metodología multicriterio, combinando análisis técnico, validación mediante el MIT/Tübingen Saliency Benchmark y evaluación de aplicabilidad en social media. Los resultados evidencian heterogeneidad arquitectónica significativa, una brecha entre precisión comercialmente reportada y verificable, y validación externa limitada. Estos hallazgos sitúan el eye tracking predictivo como herramienta diagnóstica temprana, complementaria a metodologías experimentales tradicionales.*

Recibido: 10/ 07 / 2026
Aceptado: 20/ 10 / 2026

# 1. Introducción

En un contexto como el actual de saturación de la publicidad audiovisual, de competencia por la atención de nuestras audiencias y definida por la sobrecarga cognitiva, la atención se ha convertido en un recurso escaso e invaluable (Rachmad, 2024). Adicionalmente, el diseño evoluciona desde expresión estética a herramienta que guía la atención mediante principios cognitivos y psicológicos, captándola eficientemente en plazos limitados (Yuan et al., 2025).

Esta revolución está caracterizada por la interactividad, por el contenido generado por los usuarios, por la integración de diferentes plataformas, por el auge de la personalización, así como de la información en tiempo real e instantánea (Singh & Singh, 2025).

Este entorno genera, por un lado, que las empresas tengan la posibilidad de crear una cierta percepción e imagen de marca pero, por otro lado, los consumidores de contenido tienen cada vez más opciones de elección (Sujanska & Nadanyiova, 2022).

En este sentido, las empresas han creado nuevos procesos y formas de comunicación para diferenciarse ya sea a través de la aparición de nuevas formas y modos de comunicación, así como dando paso de una narrativa más emocional que racional (Tapia Frade et al., 2025). La forma en que los elementos visuales se coloquen, como por ejemplo la marca, resulta esencial para construir el valor de la pieza, así como mejorar la eficacia del anuncio en general (Wedel & Pieters, 2000). De esta forma, es clave poder analizar qué capta la atención a los consumidores y en este sentido, los avances en neurociencia aplicada, por ejemplo, el seguimiento ocular en inglés llamado *eye tracking*, ha supuesto un avance en la medición de la atención publicitaria de forma de comprender qué estímulos generan mayor atención y *engagement* (Saavedra-Montejo et al., 2025).

Adicionalmente, los avances tecnológicos, particularmente los relacionados con la inteligencia artificial, ofrecen soluciones para tareas de automatización, generación de contenido gráfico, edición de imágenes y análisis en tiempo real del rendimiento de las publicaciones, respondiendo así a la necesidad de adaptarse a entornos dinámicos, competitivos y saturados (Arias et al., 2025). En este contexto, resulta pertinente distinguir entre dos modalidades de medición de la atención visual: el *eye tracking* tradicional y el *eye tracking* predictivo, cuyas características, ventajas y limitaciones se describen a continuación.

## *1.1. Eye tracking tradicional en comunicación visual*

El *eye tracking* ha ido ganando importancia debido a que sus métricas proveen información sobre la atención visual tales como como fijaciones y patrones de visualización (Muñoz-Leiva et al., 2019; Espigares-Jurado et al., 2020), ya que los movimientos oculares son un buen indicador de atención visual (Wedel & Pieters, 2000). De hecho, los antecedentes de las investigaciones de Just y Carpenter (1980) en su hipótesis ojo-mente señalaban que existe una correlación directa entre lo que la persona observa y su procesamiento cognitivo.

El *eye tracking* tradicional se ha consolidado como metodología fundamental para el estudio del comportamiento visual y la atención, empleando hardware especializado que registra con precisión los movimientos oculares de participantes (Holmqvist et al., 2011). Con la utilización de tecnología infrarroja para detectar la posición de la pupila y el reflejo corneal, permite determinar hacia dónde dirige su atención visual un participante en tiempo real (Duchowski, 2017). Esta técnica proporciona métricas como fijaciones (períodos donde la mirada permanece relativamente estable), sacadas (movimientos rápidos entre fijaciones), y mapas de calor que visualizan áreas de mayor concentración visual (Holmqvist et al., 2011).

Este tipo de *eye tracking* ha sido ampliamente utilizado en estudios de comportamiento del consumidor, diseño de interfaces, y análisis de contenido publicitario, demostrando su validez para comprender procesos atencionales (Holmqvist et al., 2011). Sin embargo, presenta limitaciones significativas ya que requiere equipamiento que puede resultar costoso y necesita participantes físicamente presentes para realizar los procesos de calibración que pueden ser laboriosos, limitando el tamaño de las muestras y la generalización de los resultados (Van der Cruyssen et al., 2024). Adicionalmente, Steil et al. (2019) plantean preocupaciones de privacidad

asociadas a la utilización de este tipo de dispositivo. Adicionalmente, y especialmente en contextos como las redes sociales, donde el volumen masivo de contenido y la naturaleza dinámica de los estímulos, pueden hacer muy dificultoso el análisis a gran escala mediante estos métodos tradicionales (Holmqvist et al., 2011).

Como respuesta a estas restricciones, ha emergido el *eye tracking* predictivo.

### *1.2. Eye tracking predictivo basado en IA*

El *eye tracking* predictivo, también denominado "*saliency modeling*" o "*attention prediction*", son plataformas basadas en inteligencia artificial que utilizan redes neuronales convolucionales y modelos de saliencia visual para anticipar patrones de atención sin necesidad de participantes reales (Kümmerer et al., 2017; Bylinskii et al., 2018). Estas herramientas prometen democratizar el acceso a *insights* sobre comportamiento visual, ofreciendo análisis inmediatos, escalables y a menor coste.

El eye tracking predictivo utiliza algoritmos de aprendizaje profundo (deep learning) para predecir dónde los usuarios dirigirán su atención visual (Kümmerer et al., 2017). Estos modelos se entrenan con grandes datasets de imágenes con datos reales de eye tracking, aprendiendo automáticamente características visuales que atraen la atención humana (Borji, 2021).

Los modelos más recientes han alcanzado niveles de precisión significativos en la predicción de patrones atencionales en ciertos contextos controlados (Kümmerer et al., 2017). No obstante ello, algunos estudios recientes señalan importantes limitaciones. La mayoría de estos modelos han sido entrenados y validados con imágenes estáticas de escenas naturales, lo que plantea interrogantes sobre su capacidad de generalización a contextos dinámicos (Borji, 2024) por factores sociales y contextuales como lo son las redes sociales.

Entre las ventajas que presenta el *eye tracking* predictivo destacan las siguientes. En primer lugar, su escalabilidad en términos de coste y tiempo, ya que estas soluciones predictivas analizan directamente los estímulos visuales sin requerir participación humana, permitiendo analizar variantes de diseño en minutos frente a los estudios tradicionales que involucran muestras de individuos con el consiguiente coste temporal y económico (Holmqvist et al., 2011; Kümmerer et al., 2016; Blascheck et al., 2017; Linardos et al., 2021). Esta capacidad resulta especialmente valiosa en tests A/B de creatividades publicitarias, donde la velocidad de iteración puede determinar el éxito de una campaña. En segundo lugar, ofrece ventajas en materia de protección de privacidad y cumplimiento normativo, dado que los datos obtenidos mediante *eye tracking* tradicional constituyen información biométrica particularmente sensible bajo el RGPD (European Union, 2016), pudiendo revelar información implícita sobre identidad, rasgos de personalidad, origen étnico, edad, género, emociones y preferencias (Kröger et al., 2020). El *eye tracking* predictivo elimina completamente las preocupaciones relacionadas con el consentimiento informado, el almacenamiento seguro de datos biométricos y los derechos de acceso y eliminación de datos personales (Bozkir et al., 2023; Vallejo-Blanxart et al., 2026). En tercer lugar, resulta particularmente valioso durante las fases tempranas de conceptualización y prototipado del diseño, permitiendo testear conceptos antes de su producción, a diferencia del *eye tracking* tradicional cuyo coste temporal hace casi impracticable su uso iterativo durante la conceptualización.

No obstante, esta modalidad presenta limitaciones importantes. Una limitación fundamental es su dependencia de características visuales de bajo nivel (saliencia perceptual), lo que impide capturar factores cognitivos como los objetivos específicos de la tarea, el conocimiento previo del observador o el contexto semántico, factores que influyen significativamente en la distribución real de la atención visual (Henderson et al., 2007; Tatler et al., 2011). Asimismo, existe una dependencia crítica del conjunto de datos de entrenamiento, ya que los algoritmos pueden presentar problemas de generalización cuando se aplican a poblaciones, contextos culturales o tipos de estímulos visuales que difieren significativamente de aquellos con los que fueron entrenados, comprometiendo la validez ecológica de las predicciones (Kümmerer et al., 2018; Bylinskii et al., 2018). Finalmente, el *eye tracking* predictivo se limita a estimar patrones de atención visual sin poder medir las respuestas emocionales, la carga cognitiva o las evaluaciones

afectivas que impulsan las decisiones de compra, aspectos que sí puede capturar el *eye tracking* tradicional mediante métricas como la dilatación pupilar (Holmqvist et al., 2011)

### *1.3. Atención visual en redes sociales*

Tal como se explica en apartados anteriores, la atención visual es el resultado de la actividad visual desencadenada por estímulos visuales. Ésta puede ser analizada a través *eye tracking* ofreciendo información exhaustiva sobre los patrones de atención para determinar cómo los consumidores interactúan en el medio digital e identificando que elementos visuales atraen mayor atención e influyen en su comportamiento (Riswanto et al., 2024). En este aspecto, los modelos clásicos de atención visual distinguen entre dos tipos de atención tales como la respuesta automática a estímulos salientes (*bottom-up*) y la atención guiada por objetivos (*top-down*) (Posner & Petersen, 1990). Por lo que, la medición de estos procesos atencionales cobra especial relevancia, al constituir la atención visual un predictor significativo de la efectividad publicitaria y del procesamiento de marca (Pieters & Wedel, 2004). El papel de la atención selectiva en el procesamiento de la información puede ser cuantificado mediante los patrones de atención medidos con este tipo de tecnología (Yuan et al., 2025).

En el contexto de redes sociales, donde la competencia por la atención es particularmente intensa, este tipo de enfoque cobra mucho valor para optimizar el diseño de contenido publicitario. Las plataformas digitales plantean una competencia extrema entre estímulos, donde las micro-decisiones atencionales ocurren en milisegundos (Mayer et al., 2024). Es por ello, que el *eye tracking* ha sido utilizado por profesionales del marketing para evaluar la atención visual y crear anuncios más atractivos, utilizando métricas como tiempo de fijación, las *saccades* y patrones de mirada que dan información precisa de como los consumidores interactúan con los anuncios digitales (Almourad et al., 2025).

Los estudios de *eye tracking* tradicionalmente realizados, exponiendo a sujetos a la visualización de estímulos, ha sido comúnmente usada para distintos tipos de evaluaciones en el ámbito digital pero vista la velocidad del contexto actual y la complejidad metodológica limitan su uso iterativo en ciclos creativos rápidos (Šola et al., 2024). Ante esta limitación, el *eye tracking* predictivo ofrece una alternativa que facilita el diagnóstico visual temprano al estimar dónde es probable que se dirija la atención durante los primeros segundos de exposición, período crítico dominado por procesamiento de la atención guiada por estímulos o reactiva (Bylinskii et al., 2018).

Específicamente en el ámbito de las redes sociales, diversos estudios de *eye tracking* se han realizado para medir la atención en relación al contenido presentado. Vraga et al. (2016) analizaron las diferencias de atención según temas y estilos en contenido de redes sociales, mientras que Muñoz-Leiva et al. (2019) evaluaron la eficacia de la publicidad en términos de atención visual y recuerdo, y Piotrkowicz et al. (2017) investigaron cómo las redes sociales se convertían en el punto de partida de la información de los usuarios. Estudios más recientes han abordado ámbitos específicos, como Li et al. (2025) sobre noticias en redes sociales o Chen-Sankey et al. (2025) sobre la publicidad de cigarrillos desechables en Instagram. Adicionalmente, Gheorghe et al. (2023) destacan cómo el *eye tracking* puede revelar factores inconscientes que influyen en las decisiones de los consumidores, factores que no son obtenidos a través de métodos tradicionales de investigación de mercados como encuestas y focus groups.

Por lo tanto, podemos concluir que existe una necesidad de evaluación científica de modelos de *eye tracking* predictivo para la aplicación en redes sociales.

### *1.4. Plataformas comerciales de eye tracking predictivo*

El *eye tracking* predictivo se fundamenta en modelos como el de saliencia de Itti et al. (1999), que predicen computacionalmente las fijaciones visuales sin necesidad de participantes humanos, utilizando características de bajo nivel como color, orientación e intensidad. La evolución tecnológica mediante *deep learning* ha mejorado sustancialmente estas predicciones, demostrando que las representaciones internas aprendidas por redes neuronales pueden reutilizarse para predecir fijaciones con mejor rendimiento que los métodos clásicos (Kümmerer

et al., 2016). A diferencia del *eye tracking* tradicional, que mide fijaciones en condiciones específicas con procesamiento *top-down* orientado a tareas concretas, el predictivo estima probabilidades basándose en regularidades estadísticas y modela principalmente la atención inicial *bottom-up* (Torralba et al., 2006).

En el contexto de redes sociales, donde los usuarios visualizan posts integrados en un *feed* con expectativas específicas sobre la ubicación de elementos clave como titulares, rostros o *call-to-action* (Vraga et al., 2016), estos modelos combinan saliencia perceptual con comprensión global de la escena (Torralba et al., 2006), resultando especialmente útiles como herramienta de pre-diagnóstico y optimización temprana antes de validaciones empíricas más profundas (Šola et al., 2024).

La transición de estas tecnologías al ámbito comercial ha generado un ecosistema de plataformas que democratizan el acceso a análisis de atención visual, aunque persiste una brecha significativa entre las afirmaciones de alta precisión de estas soluciones comerciales y la evidencia científica que las respalda. La literatura reciente advierte sobre la necesidad de mayor transparencia metodológica y validación específica (Borji, 2024). Permanecen como cuestiones abiertas la validez científica de estas plataformas, su capacidad para replicar resultados empíricos y sus limitaciones metodológicas en comparación con el *gold standard* del *eye tracking* tradicional, requiriéndose mayor investigación empírica sobre su validez ecológica en contextos digitales contemporáneos.

## 2. Objetivos

El presente estudio tiene como objetivo general analizar comparativamente las principales plataformas comerciales de *eye tracking* predictivo basadas en inteligencia artificial, evaluando su idoneidad para el análisis de contenido en redes sociales.

De forma específica, se plantean los siguientes objetivos: (1) caracterizar las plataformas en términos de escalabilidad, tecnología subyacente, tipos de *output* generados y consideraciones de privacidad; (2) validar la exactitud predictiva de las plataformas mediante contraste con *benchmarks* estandarizados (MIT/Tübingen Saliency Benchmark); y (3) evaluar la aplicabilidad práctica de cada plataforma para el análisis de formatos característicos de redes sociales.

## 3. Metodología

Este estudio emplea una metodología de evaluación comparativa multicriterio para analizar herramientas de *eye tracking* predictivo basadas en inteligencia artificial aplicables al contexto de contenidos de redes sociales. El diseño metodológico se estructura en cinco fases secuenciales: selección de plataformas, definición del marco evaluativo, procedimiento de recogida de datos, validación de exactitud mediante *benchmark* externo, y evaluación de aplicabilidad en redes sociales.

### *3.1. Selección de plataformas*

Se identificaron las plataformas de *eye tracking* predictivo mediante revisión de literatura especializada en neuromarketing y saliencia visual, análisis de mercado sectorial y documentación técnica disponible públicamente. Los criterios de inclusión fueron: (a) disponibilidad comercial activa en el período 2024-2025, (b) tecnología basada en modelos de saliencia visual con inteligencia artificial, (c) capacidad de generación de mapas de atención predictivos, y (d) aplicabilidad declarada al análisis de contenido digital o redes sociales. Se excluyeron las plataformas sin documentación técnica accesible o sin información verificable sobre su rendimiento.

La muestra final comprende diez plataformas: Attention Insight, Feng-GUI, Clueify, Emotiva AI (Foresight), Forebrain (Attentive AI), expoze.io (alpha.one), Neurons, 3M VAS, EyeQuant y Brainsight. Esta selección representa el espectro actual de soluciones comerciales con relevancia tanto en el ámbito académico como en la práctica profesional del marketing digital.

### *3.2. Marco de evaluación multicriterio*

El análisis comparativo se articuló en torno a cinco dimensiones evaluativas definidas a priori, siguiendo los principios de los marcos de selección tecnológica multicriterio (Wątróbski et al., 2019).

**Escalabilidad**: capacidad de analizar un volumen elevado de piezas gráficas de forma eficiente, incluyendo disponibilidad de API, procesamiento por lotes y tiempo de respuesta por análisis.

**Tecnología**: tipo de salidas generadas (mapas de calor, *gaze plots*, *focus maps*, métricas cuantitativas), arquitectura del modelo de IA subyacente y métricas complementarias ofrecidas.

**Exactitud (precisión)**: capacidad predictiva del modelo para anticipar las fijaciones oculares humanas, evaluada tanto mediante las métricas reportadas por los proveedores como mediante validación externa en *benchmarks* estandarizados.

- **Privacidad**: requisitos de tratamiento de datos (procesamiento en nube vs. local), políticas de retención de imágenes y cumplimiento de normativas de protección de datos, aspecto especialmente relevante para contenido corporativo confidencial.

**Aplicabilidad en redes sociales**: adecuación de cada plataforma a los formatos característicos del ecosistema de social media (imágenes estáticas, *stories, reels, thumbnails*), incluyendo optimizaciones específicas para entornos móviles o *feeds* verticales.

### *3.3. Procedimiento de recogida de datos*

La información técnica se extrajo de la documentación oficial de cada plataforma (sitios web corporativos, *whitepapers*, documentación de API y casos de estudio publicados) durante el período enero-mayo 2025. Para cada plataforma se registraron: el tipo de outputs visuales y analíticos generados, la precisión declarada comercialmente, el modelo de acceso (gratuito, *freemium,* pago por uso) y los formatos de contenido soportados.

Cabe señalar que ninguna de las herramientas analizadas divulga públicamente los detalles arquitectónicos de su modelo de IA propietario, una limitación común en el sector que afecta a la replicabilidad científica. En términos generales, estas plataformas emplean modelos de saliencia visual entrenados con datos de movimientos oculares humanos, típicamente redes neuronales profundas que aprenden a predecir mapas de atención equivalentes a los obtenidos mediante *eye tracking* tradicional (Kümmerer et al., 2017).

El presente estudio no implica entrenamiento, ajuste ni modificación de los modelos analizados, sino exclusivamente el análisis comparativo de información técnica y métricas disponibles públicamente.

### *3.4. Validación de exactitud mediante benchmark externo*

Dada la inviabilidad de realizar estudios de seguimiento ocular tradicional para cada plataforma por restricciones de coste y tiempo (Duchowski, 2017), se adoptó un enfoque de validación secundaria mediante los resultados públicos del MIT/Tübingen Saliency Benchmark, el estándar de referencia en el campo de la predicción de fijaciones oculares (Kümmerer et al., 2018).

Se emplearon dos conjuntos de datos con fijaciones humanas *held-out* (no públicas para evitar sobreajuste):

**MIT300** (Judd et al., 2012): 300 imágenes naturales de escenas interiores y exteriores con datos de fijación de 39 observadores, duración de visualización de 3 segundos, capturados con eye tracker ETL 400 ISCAN (240 Hz).

**CAT2000** (Borji & Itti, 2015): 4000 imágenes distribuidas en 20 categorías temáticas, con datos de fijación de 24 observadores por imagen, duración de visualización de 5 segundos, capturados con EyeLink 1000 (1000 Hz).

Para cada plataforma con resultados publicados en estos *benchmarks,* se recopilaron dos métricas: el valor AUC-Judd (*Area Under the ROC Curve*), que cuantifica la capacidad del modelo para discriminar entre localizaciones fijadas y no fijadas tratando el mapa de saliencia como un clasificador binario (Riche et al., 2013); y el valor *Gold Standard*, que representa el límite superior

teórico de predicción calculado mediante estimación de densidad de *kernel* gaussiano sobre las fijaciones de un número hipotéticamente infinito de observadores.

Con estos valores se calculó una precisión relativa normalizada respecto al *Gold Standard* humano, mediante la fórmula:

$$\text{Precisión relativa (\%)} = \frac{AUC}{Gold\ Standard} \times 100$$

Esta métrica expresa qué porcentaje del rendimiento humano óptimo alcanza cada modelo, permitiendo comparaciones objetivas entre plataformas independientemente del *dataset* utilizado y controlando las diferencias individuales entre observadores. A diferencia de la *accuracy* clásica en clasificación, esta precisión relativa cuantifica la proximidad al techo teórico de predicción humana, no la proporción de aciertos binarios.

Se categorizó la fuente de verificación en dos tipos: (a) verificación MIT, cuando la plataforma aparece registrada en los resultados oficiales del *benchmar*k (https://saliency.tuebingen.ai), y (b) auto-reportada (*self-reported*), cuando la cifra proviene exclusivamente de la documentación comercial sin auditoría independiente.

### *3.5. Evaluación de aplicabilidad en redes sociales*

Para valorar la idoneidad práctica de cada plataforma en entornos de social media, se realizó un análisis funcional basado en las versiones de demostración disponibles y la documentación oficial de cada proveedor. Se examinaron las funcionalidades declaradas, los formatos de contenido soportados (imágenes estáticas, vídeo, *stories*) y los casos de uso recomendados para diferentes plataformas sociales. Se registraron además el modelo de acceso comercial, la velocidad de procesamiento declarada y la existencia de optimizaciones específicas para formatos móviles o vídeo corto.

## 4. Resultados

### *4.1. Características técnicas de las plataformas*

Todas las herramientas analizadas generan como output principal un mapa de calor (*heatmap*) predictivo que indica las regiones de la imagen con mayor probabilidad de captar la atención visual. Más allá de este denominador común, las plataformas difieren sustancialmente en las visualizaciones y métricas complementarias que ofrecen (Tabla 1).

Attention Insight y Clueify proporcionan además *focus maps* y porcentajes de atención por áreas de interés (AOI) definidas por el usuario, facilitando la evaluación de elementos específicos del diseño (logotipos, CTAs, textos principales). Brainsight incorpora *gaze plots* simulados que representan secuencias de fijación, junto con puntuaciones de claridad visual. Emotiva AI (Foresight) se diferencia por integrar predicción de respuestas emocionales básicas junto a los mapas de fijación, adoptando un enfoque de neuromarketing más amplio. Neurons y 3M VAS incluyen métricas de carga cognitiva estimada y secuencias temporales de fijación respectivamente.

**Tabla 1**. Características técnicas de las plataformas de *eye tracking* predictivo. Se indica la precisión reportada comercialmente (MIT = verificación mediante benchmark; self = auto-reportada), el tipo de salidas generadas y el tipo de Algoritmo de IA usado

| Plataforma | Precisión reportada (fuente) | Tipo de generación | Algoritmo de IA |
|---|---|---|---|

| | | | |
|---|---|---|---|
| **Attention Insight** | 96% precisión (benchmark MIT) | Mapas de calor y mapas de atención visual, porcentajes de atención por áreas y métricas de claridad del diseño. Reportes instantáneos y comparaciones de diseño. | Deep Learning (CNN) |
| **Feng-GUI** | 92% precisión (benchmark MIT) | Mapas de calor, recorrido visual, focus maps, reportes de áreas de interés, reportes estéticos, reportes de vídeos, posibilidad de comparar reportes, detección automática de objetos. | Modelo biológico-computacional (Itti-Koch) de saliencia visual. |
| **Clueify** | 92% precisión (benchmark MIT) | Medición de la atención a través de áreas críticas. Mapas de calor, recorridos visuales y mapas de atención visual. Áreas de interés para cuantificar la atención. | Deep Learning (ANN) |
| **Emotiva AI (Foresight)** | No reporta precisión, pero sí los datos exactos del benchmark MIT | Medición de los niveles de atención, la capacidad de atención y compromiso emocional. Densidad de las fijaciones, ratio de claridad y distribución de la atención. | Deep Learning (CNN) |
| **Forebrain (Attentive AI)** | N/D | Heatmaps, métricas publicitarias | Deep Learning (CNN) |
| **expoze.io (alpha.one)** | 95% precisión (self) | Cuantificación de la atención a través de las áreas de interés | Deep Learning (CNN) |
| **Neurons AI** | 95% precisión (self) | Mapas de calor, mapas de fijación, métricas de claridad, carga cognitiva | Deep Learning (ANN bayesiano) |
| **3M VAS** | 92% precisión (self) | Mapas de probabilidad de fijación, secuencia de fijaciones y mapas tipo heatmap para estímulos estáticos. | Algoritmos de visión artificial |
| **EyeQuant** | 90% precisión (self reported) | Mapas de calor, imágenes y análisis de vídeo. | Machine Learning tradicional |
| **Brainsight** | 94% precisión (self) | Mapas de calor, seguimiento de la mirada, mapas de visibilidad instantánea, además de ratios de atención y claridad. | Deep Learning (CNN) |

Fuente(s): Elaboración propia

Respecto a la arquitectura de los modelos de IA, las plataformas analizadas en la Tabla 1 presentan diversidad en sus aproximaciones tecnológicas. La mayoría emplea técnicas de *Deep Learning*, predominando las redes neuronales convolucionales (CNN) en Attention Insight, Emotiva AI (Foresight), Forebrain (Attentive AI), expoze.io y Brainsight, mientras que Clueify utiliza redes neuronales artificiales (ANN) y Neurons AI implementa un enfoque bayesiano con predicciones probabilísticas. En contraste, Feng-GUI se fundamenta en el modelo biológico-computacional de saliencia visual de Itti-Koch, y 3M VAS emplea algoritmos de visión artificial basados en reglas predefinidas derivadas de la neurociencia. EyeQuant representa una aproximación mediante Machine Learning supervisado tradicional.

### *4.2. Validación de precisión mediante benchmark*

La Tabla 2 presenta los resultados de la validación de precisión. De las diez plataformas analizadas, cinco disponen de resultados verificables en el MIT/Tübingen Saliency Benchmark: Attention Insight, Feng-GUI, Clueify, Emotiva AI (Foresight) y Forebrain (Attentive AI). Las restantes —expoze.io, Neurons, 3M VAS, EyeQuant y Brainsight— reportan cifras de precisión únicamente en su documentación comercial sin validación externa independiente.

**Tabla 2**. Validación de precisión mediante el MIT/Tübingen Saliency Benchmark. Precisión calculada = (AUC/Gold Standard) × 100. El símbolo "-" indica ausencia de datos verificables. MIT = verificación por *benchmark*; self = auto-reportada.

| Plataforma | Precisión reportada con verificación (fuente) | MIT benchmark | Precisión calculada | *Gold Standard* | AUC | Último test |
|---|---|---|---|---|---|---|
| **Attention Insight** | 96% precisión (MIT) | MIT300 | **92%** | 0.9341 | 0.864 | 2021/11 |
| | | MIT300 (MIT) | **95%** | 0.92 | 0.87 | 2019/06 |
| **Feng-GUI** | 92% precisión (MIT) | MIT300 (MIT) | **88%** | 0.92 | 0.81 | 2018/06 |
| | | CAT2000 (MIT) | **92%** | 0.9 | 0.83 | 2018/06 |
| **Clueify** | 92% precisión (MIT) | MIT300 | **94%** | 0.9341 | 0.8811 | 2023/03 |
| **Emotiva AI (Foresight)** | No reporta datos de precisión, pero sí datos benchmark MIT300 | MIT300 | **92%** | 0.9341 | 0.8636 | 2025/01 |
| | | CAT2000 | **93%** | 0.9159 | 0.8556 | 2025/01 |
| **Forebrain (Attentive AI)** | N/D | CAT2000 | **94%** | 0.9159 | 0.8598 | 2024/07 |
| **expoze.io (alpha.one)** | N/D - Solo auto-reportada | | | | | |
| **Neurons AI** | N/D - Solo auto-reportada | | | | | |
| **3M VAS** | N/D - Solo auto-reportada | | | | | |
| **EyeQuant** | N/D - Solo auto-reportada | | | | | |
| **Brainsight** | N/D - Solo auto-reportada | | | | | |

Fuente(s): Elaboración propia

Se observa una discrepancia entre la precisión reportada comercialmente y la precisión relativa calculada a partir de los datos del *benchmark*. Attention Insight publicita un 96% de precisión, mientras que la precisión relativa calculada oscila entre 92,5% (MIT300, 2021) y 94,6% (MIT300, 2019). Feng-GUI, con un 92% reportado, alcanza 88,0% en MIT300 pero 92,2% en CAT2000, sugiriendo variabilidad según el tipo de estímulos. Clueify representa un caso particular: con 92% reportado, alcanza 94,3% calculado en MIT300 (2023), siendo la única plataforma cuya precisión verificada supera la cifra comercial. Emotiva AI (Foresight), evaluada en enero 2025, obtiene 92,5% (MIT300) y 93,4% (CAT2000). Forebrain (Attentive AI), evaluada en julio 2024, alcanza 93,9% en CAT2000.

Ninguna plataforma alcanza el 100% teórico del *Gold Standard*, debido a factores de atención *top-down* y diferencias individuales entre observadores que los modelos actuales no capturan completamente (Borji & Itti, 2015).

Para las plataformas sin validación externa, las precisiones auto-reportadas oscilan entre 90% y 95%, pero la ausencia de detalles metodológicos publicados dificulta evaluar su comparabilidad (Bylinskii et al., 2018).

### *4.3. Aplicabilidad en redes sociales*

La Tabla 3 presenta las características de acceso y cobertura de formatos de cada plataforma para el análisis de contenido en redes sociales.

En cuanto al modelo de acceso, seis plataformas ofrecen modalidades de prueba gratuita (Attention Insight, Clueify, 3M VAS, EyeQuant, Brainsight) o *freemium* (expoze.io). Feng-GUI y Neurons operan exclusivamente bajo modelo de pago por uso o suscripción. Respecto a los formatos soportados, todas las plataformas analizan imágenes estáticas. Expoze.io y Neurons incorporan además capacidad de análisis de vídeo. Clueify incluye simulación de visualización en entorno móvil.

**Tabla 3**. Aplicabilidad de las plataformas de *eye tracking* predictivo al análisis de contenido en redes sociales. Se indica el modelo de acceso comercial, los formatos de contenido soportados y las funcionalidades específicas de cada plataforma.

| Plataforma | Tipo de acceso | Formatos soportados | Funcionalidades específicas para Redes Sociales |
|---|---|---|---|
| **Attention Insight** | Trial gratuito | Imágenes | Métricas de claridad, % atención por AOI, evaluación de CTAs |
| **Feng-GUI** | Pago por uso | Imágenes, vídeo | Métricas de saliencia, contraste visual |
| **Clueify** | Trial gratuito | Imágenes | Simulación de entorno móvil (feed vertical). Ideal para tests A/B. |
| **expoze.io** | Freemium | Imágenes, vídeo | Análisis frame-by-frame, procesamiento rápido |
| **Neurons** | Pago por uso | Imágenes, vídeo | Modelos para feed vertical, predicción de scroll |
| **3M VAS** | Trial gratuito | Imágenes | Secuencia temporal de fijaciones, análisis de primeros 0,5 seg |
| **EyeQuant** | Trial gratuito | Imágenes | Métricas de claridad/saturación visual |
| **Brainsight** | Trial gratuito | Imágenes | Predicción de CTR, scores de atención |

Fuente(s): Elaboración propia

## 5. Conclusiones y Discusiones

La heterogeneidad identificada entre las plataformas comerciales de *eye tracking* predictivo tiene implicaciones metodológicas relevantes para su evaluación comparativa. Las diferencias observadas no se limitan a funcionalidades o formatos de salida, sino que responden a aproximaciones algorítmicas distintas, que incluyen modelos de *Deep Learning* entrenados con grandes volúmenes de fijaciones humanas, modelos biológico-computacionales clásicos de saliencia visual, y enfoques derivados de principios de la neurociencia visual. Esta diversidad introduce supuestos atencionales diferenciados que dificultan la comparación directa entre herramientas. En este contexto, la validación mediante *benchmarks* estandarizados se consolida como el criterio común más defendible para sostener comparabilidad interplataforma y distinguir evidencia verificable de comunicación comercial, especialmente cuando la arquitectura interna de los modelos permanece opaca (Kümmerer et al., 2018; Borji, 2024). Los resultados ponen de manifiesto, además, una brecha persistente entre la precisión comunicada comercialmente (90-96%) y la precisión relativa verificable en el MIT/Tübingen Saliency Benchmark (88-94%), junto con un patrón de validación externa parcial, donde solo cinco de las diez plataformas analizadas aportan contraste independiente. En conjunto, estos hallazgos permiten situar el *eye tracking* predictivo como una herramienta diagnóstica temprana, especialmente valiosa por su escalabilidad y rapidez en entornos de redes sociales, pero no equivalente al gold standard

experimental. A partir de estos resultados, se derivan contribuciones diferenciadas para la investigación académica y la práctica profesional.

### *5.1 Contribuciones teóricas*

El estudio contribuye, en primer lugar, a un replanteamiento del *eye tracking* predictivo dentro de un continuo metodológico más amplio de análisis de la atención visual. Frente a enfoques que oponen el *eye tracking* tradicional y el predictivo como alternativas excluyentes, los resultados permiten situarlos como modalidades complementarias, adecuadas para objetivos analíticos distintos. Mientras el *eye tracking* tradicional conserva su papel en contextos experimentales controlados y orientados a procesos cognitivos complejos, el *eye tracking* predictivo resulta especialmente pertinente en fases tempranas del proceso creativo, en análisis a gran escala y en escenarios donde la atención inicial guiada por estímulos visuales es el foco principal. Esta distinción permite identificar escenarios diferenciales de aplicación según la fase del proceso creativo, la escala del análisis y el objetivo cognitivo y atencional, superando enfoques centrados únicamente en la validación técnica aislada (Kümmerer et al., 2017; Duchowski, 2017; Tatler et al., 2011).

En segundo lugar, el trabajo aporta una lectura explicativa del papel de la arquitectura algorítmica en la evaluación comparativa de plataformas comerciales de *eye tracking* predictivo. El análisis identifica la coexistencia de tres enfoques principales: modelos de *Deep Learning* entrenados con grandes *datasets* de fijaciones humanas para aprender patrones estadísticos de atención; modelos clásicos de saliencia visual centrados en mecanismos bottom-up (Posner & Petersen, 1990; Itti et al., 1999); y enfoques híbridos que incorporan métricas derivadas de la neurociencia visual. Estos enfoques modelan niveles distintos del procesamiento atencional, presentan limitaciones específicas de generalización contextual y pueden generar outputs visuales similares bajo supuestos cognitivos diferentes. En consecuencia, las diferencias algorítmicas no invalidan la comparación entre plataformas, pero exigen una contextualización metodológica rigurosa apoyada en validación externa, reforzando el papel de los *benchmark*s estandarizados como criterio de nivelación frente a la opacidad de los modelos propietarios (Torralba et al., 2006; Kümmerer et al., 2016, 2017; Borji, 2024).

Una tercera contribución reside en la propuesta de un marco de evaluación multicriterio para plataformas comerciales de *eye tracking* predictivo aplicadas al marketing digital. El modelo integra cinco dimensiones de análisis: escalabilidad, tecnología, exactitud, privacidad y aplicabilidad contextual, respondiendo a la ausencia de marcos sistemáticos para evaluar tecnologías comerciales basadas en inteligencia artificial en contextos aplicados. La abstracción de estas dimensiones facilita, además, la transferibilidad conceptual del marco a la evaluación de otras soluciones de neuromarketing predictivo (Wątróbski et al., 2019; Borji, 2024).

En cuarto lugar, la investigación contribuye a la conceptualización de la brecha entre validación científica y comunicación comercial en herramientas de *eye tracking* predictivo. Los resultados documentan empíricamente la desconexión entre las cifras de precisión comunicadas por los proveedores y la evidencia verificable disponible, poniendo de relieve el impacto de los algoritmos propietarios y la limitada transparencia metodológica sobre la replicabilidad científica (Kümmerer et al., 2018; Van der Cruyssen et al., 2024).

Finalmente, el estudio sitúa el *eye tracking* predictivo dentro del ecosistema específico de las redes sociales, caracterizado por *feeds* dinámicos, *scroll* continuo y ventanas de atención inicial de muy corta duración. Esta contextualización permite vincular la literatura sobre saliencia visual con los patrones de atención propios de las plataformas sociales y conceptualizar el *eye tracking* predictivo como un instrumento integrado en procesos creativos ágiles del marketing digital contemporáneo, más que como una herramienta de medición finalista (Vraga et al., 2016; Muñoz-Leiva et al., 2019; Mayer et al., 2024; Šola et al., 2024).

### *5.2 Contribuciones prácticas*

Desde una perspectiva aplicada, los resultados permiten derivar criterios operativos para la selección de plataformas de *eye tracking* predictivo según el contexto de aplicación. El análisis

evidencia que la idoneidad de cada herramienta depende del tipo de contenido y del entorno de difusión. En el caso de contenido estático corporativo, como *banners*, publicaciones en LinkedIn o anuncios *display*, resultan útiles las plataformas que ofrecen métricas de claridad visual y jerarquía informativa, facilitando la evaluación de la prominencia del mensaje principal y los elementos de llamada a la acción. Para entornos de *feed* móvil con *scroll* vertical continuo, las herramientas que incorporan simulación de visualización en *smartphone* aportan valor diferencial al anticipar la competencia atencional real entre estímulos (Xie et al., 2024). En formatos dinámicos y de vídeo corto, como *stories, reels* o TikTok, las plataformas con análisis temporal y *frame* a *frame* permiten aproximarse al comportamiento atencional a lo largo de la secuencia visual. Finalmente, en el análisis de miniaturas y *thumbnails*, especialmente en plataformas de vídeo, las soluciones orientadas a la captación atencional en los primeros cientos de milisegundos resultan más adecuadas para evaluar la probabilidad inicial de clic.

En segundo lugar, el estudio ofrece una guía práctica para profesionales del marketing digital al poner de relieve la necesidad de alinear la selección de herramientas con el equilibrio entre velocidad de iteración, nivel de validación y coste de acceso. El *eye tracking* predictivo se perfila como solución valiosa en fases tempranas de conceptualización y prototipado creativo, donde la rapidez y escalabilidad priman sobre la precisión experimental absoluta. Su uso permite iterar diseños, realizar tests A/B preliminares y optimizar creatividades antes de acometer inversiones publicitarias de mayor envergadura (Šola et al., 2024), reservando metodologías experimentales más costosas para fases posteriores. Adicionalmente, la ausencia de procesamiento de datos biométricos personales simplifica el cumplimiento normativo en entornos corporativos con políticas estrictas de protección de datos. No obstante, esta agilidad operativa no exime de una valoración crítica de las métricas proporcionadas por cada plataforma, dado que la precisión comunicada comercialmente no siempre se corresponde con la evidencia verificable mediante *benchmarks* independientes.

Por último, las implicaciones prácticas refuerzan la idea de que el *eye tracking* predictivo debe entenderse como complemento dentro de flujos de trabajo creativos ágiles, y no como sustituto de técnicas empíricas tradicionales. Integrado de este modo, su valor reside en facilitar decisiones informadas bajo restricciones reales de tiempo y presupuesto, mejorando la eficiencia del proceso creativo y la coherencia visual de los contenidos en entornos de redes sociales altamente competitivos (Almourad et al., 2025; Mayer et al., 2024; Yuan et al., 2025).

## 6. Limitaciones y líneas futuras de investigación

Este estudio presenta varias limitaciones que deben considerarse al interpretar los resultados. En primer lugar, el análisis comparativo se basa en información técnica y métricas de precisión disponibles públicamente, lo que implica una dependencia inevitable de datos auto-reportados en aquellas plataformas que no aportan validación externa independiente. Asimismo, la utilización de *benchmarks* estandarizados, aunque necesaria para garantizar comparabilidad, se apoya en conjuntos de imágenes estáticas y escenas naturales, lo que puede limitar la generalización de los resultados a formatos dinámicos y multimodales característicos de las redes sociales. Por último, la opacidad de los modelos propietarios impide un examen detallado de los mecanismos internos de aprendizaje y de sus posibles sesgos.

A partir de estas limitaciones, futuras líneas de investigación deberían avanzar hacia validaciones empíricas específicas en contextos de social media, combinando *eye tracking* predictivo con estudios experimentales tradicionales para evaluar su grado de complementariedad en escenarios reales. Resulta igualmente pertinente explorar el rendimiento de estos modelos en contenidos dinámicos, interactivos y personalizados, así como analizar su comportamiento en distintos contextos culturales y dispositivos. Finalmente, el desarrollo de marcos de transparencia y auditoría para plataformas comerciales de inteligencia artificial se perfila como una línea de investigación prioritaria para reforzar la replicabilidad y la confianza científica en este tipo de herramientas.

## 7. Referencias


Almourad, M. B., Bataineh, E., Hussein, M., & Wattar, Z. (2025). Strategic placement of branding elements in digital marketing: Insights from eye-tracking data. Proceedings of the 27th International Conference on Enterprise Information Systems, 2, 417–423. https://doi.org/10.5220/0013281500003929

Arias, M. A. S., Báscones, G. G. U., Donoso, A. P. V., & Oña, A. O. C. (2025). El impacto de la Inteligencia Artificial en la producción de contenidos para Instagram: Automatización, Creatividad y Engagement. *Revista Científica Multidisciplinar G-nerando*, *6*(1), 6382. https://doi.org/10.60100/rcmg.v6i1.708

Blascheck, T., Kurzhals, K., Raschke, M., Burch, M., Weiskopf, D., & Ertl, T. (2017). Visualization of *eye tracking* data: A taxonomy and survey. *Computer Graphics Forum*, *36*(8), 260-284. https://doi.org/10.1111/cgf.13079

Borji, A. (2024). *Addressing a fundamental limitation in deep vision models: lack of spatial attention*. *arXiv preprint* arXiv:2407.01782.

Borji, A., & Itti, L. (2015). CAT2000: A large scale fixation dataset for boosting saliency research. En *2015 IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)* (pp. 1-4). IEEE. https://arxiv.org/abs/1505.03581

Bozkir, E., Özdel, S., Wang, M., David-John, B., Gao, H., Butler, K., Jain, E., & Kasneci, E. (2023). Eye-tracked virtual reality: A comprehensive survey on methods and privacy challenges. *arXiv*. https://doi.org/10.48550/arXiv.2305.14080

Bylinskii, Z., Judd, T., Oliva, A., Torralba, A., & Durand, F. (2018). What do different evaluation metrics tell us about saliency models?. *IEEE transactions on pattern analysis and machine intelligence*, *41*(3), 740-757. https://doi.org/10.1109/TPAMI.2018.2815601

Chen-Sankey, J., Weiger, C., La Capria, K., Vassey, J., Jeong, M., Phan, L., Unger, J. B., Allem, J.-P., Berg, C. J., & Choi, K. (2025). Young adults' visual attention to features of social media marketing for disposable e-cigarettes and associated perceptions. *Addiction*, *120*(3), 439-451. https://doi.org/10.1111/add.16586.

Duchowski, A. T. (2017). *Eye tracking methodology: Theory and practice* (3rd ed.). Springer. https://doi.org/10.1007/978-3-319-57883-5

Espigares-Jurado, F., Muñoz-Leiva, F., Correia, M. B., Sousa, C. M. R., Ramos, C. M. Q., & Faísca, L. (2020). Visual attention to the main image of a hotel website based on its position, type of navigation and belonging to Millennial generation: An *eye tracking* study. *Journal of Retailing and Consumer Services*, *52*, 101906. https://doi.org/10.1016/j.jretconser.2019.101906

European Union. (2016). Reglamento (UE) 2016/679 del Parlamento Europeo y del Consejo, de 27 de abril de 2016, relativo a la protección de las personas físicas en lo que respecta al tratamiento de datos personales y a la libre circulación de estos datos (Reglamento general de protección de datos). Diario Oficial de la Unión Europea, *L 119*, 1–88. Bruselas. https://eur-lex.europa.eu/eli/reg/2016/679/oj

Gheorghe, C. M., Purcărea, V. L., & Gheorghe, I. R. (2023). Using eye-tracking technology in Neuromarketing. *Romanian Journal of Ophthalmology*, *67*(1), 2-6. https://doi.org/10.22336/rjo.2023.2

Henderson, J. M., Brockmole, J. R., Castelhano, M. S., & Mack, M. (2007). Image salience versus cognitive control of eye movements in real-world scenes: *Evidence from visual search.* Eye Movements Research, 12(3), 537–562.

Holmqvist, K., Nyström, M., Andersson, R., Dewhurst, R., Jarodzka, H., & Van de Weijer, J. (2011). *Eye tracking: A comprehensive guide to methods and measures*. Oxford University Press.

Itti, L., Braun, J., Lee, D. K., & Koch, C. (1999). Attentional modulation of human pattern discrimination psychophysics reproduced by a quantitative model. *Advances in Neural Information Processing Systems*, 11, 789–795.

Just, M. A., & Carpenter, P. A. (1980). A theory of reading: From eye fixations to comprehension. *Psychological Review*, *87*(4), 329-354. https://doi.org/10.1037/0033-295X.87.4.329

Judd, T., Durand, F., & Torralba, A. (2012). *A benchmark of computational models of saliency to predict human fixations* (MIT-CSAIL-TR-2012-001). Massachusetts Institute of Technology, Computer Science and Artificial Intelligence Laboratory. http://hdl.handle.net/1721.1/68590

Kröger, J. L., Lutz, O. H.-M., & Müller, F. (2020). What does your gaze reveal about you? On the privacy implications of *eye tracking*. *Privacy and Identity Management*, 576, 226–241. https://doi.org/10.1007/978-3-030-42504-3_15

Kümmerer, M., Wallis, T. S. A., & Bethge, M. (2016). *DeepGaze II: Reading fixations from deep features trained on object recognition* (arXiv:1610.01563). arXiv. https://arxiv.org/abs/1610.01563

Kümmerer, M., Wallis, T. S. A., Gatys, L. A., & Bethge, M. (2017). Understanding low- and high-level contributions to fixation prediction. *Proceedings of the IEEE International Conference on Computer Vision*, 4789–4798. https://doi.org/10.1109/ICCV.2017.513

Kümmerer, M., Wallis, T. S. A., & Bethge, M. (2018). Saliency benchmarking made easy: Separating models, maps and metrics. *Computer Vision – ECCV 2018*, 11210, 770–787. https://doi.org/10.1007/978-3-030-01270-0_47

Li, X., Tse, Y. K., & Bu, X. (2025). Examining corporate social irresponsibility in manufacturing: An eye-tracking study of social media news. *International Journal of Production Economics*, *281*, Article 109539. https://doi.org/10.1016/j.ijpe.2025.109539

Linardos, A., Kümmerer, M., Press, O., & Bethge, M. (2021). DeepGaze IIE: Calibrated prediction in and out-of-domain for state-of-the-art saliency modeling. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 12919–12928. https://doi.org/10.1109/ICCV48922.2021.01268

Mayer, A.-T., Ohme, J., Maslowska, E., & Segijn, C. M. (2024). Headlines, pictures, likes: Attention to social media newsfeed post elements on smartphones and in public. *Social Media + Society*, *10*(2), Article 20563051241245666. https://doi.org/10.1177/20563051241245666

Muñoz-Leiva, F., Hernández-Méndez, J., & Gómez-Carmona, D. (2019). Measuring advertising effectiveness in Travel 2.0 websites through eye-tracking technology. *Physiology & Behavior*, *200*, 83–95. https://doi.org/10.1016/j.physbeh.2018.03.002

Pieters, R., & Wedel, M. (2004). Attention capture and transfer in advertising: Brand, pictorial, and text-size effects. *Journal of Marketing*, 68(2), 36–50. https://doi.org/10.1509/jmkg.68.2.36.27794

Piotrkowicz, A., Dimitrova, V., Otterbacher, J., & Markert, K. (2017). Headlines matter: Using headlines to predict the popularity of news articles on Twitter and Facebook. *Proceedings of the International AAAI Conference on Web and Social Media*, 11(1), 656–659. https://doi.org/10.1609/icwsm.v11i1.14951

Posner, M. I., & Petersen, S. E. (1990). The attention system of the human brain. *Annual Review of Neuroscience*, *13*, 25–42. https://doi.org/10.1146/annurev.ne.13.030190.000325

Rachmad, Y. E. (2024). Attention-attracting strategy theory. In *Digital marketing theories: From gimmicks to loyalty*. PT Sonpedia Publishing Indonesia..

Riche, N., Duvinage, M., Mancas, M., Gosselin, B., & Dutoit, T. (2013). Saliency and human fixations: State-of-the-art and study of comparison metrics. *Proceedings of the IEEE International Conference on Computer Vision* https://doi.org/10.1109/ICCV.2013.147

Riswanto, A. L., Ha, S., Lee, S., & Kwon, M. (2024). Online reviews meet visual attention: A study on consumer patterns in advertising, analyzing customer satisfaction, visual engagement, and purchase intention. *Journal of Theoretical and Applied Electronic Commerce Research*, *19*(4), 3102–3122. https://doi.org/10.3390/jtaer19040150

Saavedra-Montejo, Á., Blanco Moreno, S., & Ballester, E. (2025). Neurociencia e influencers al servicio de la atención. *Investigación y Marketing*, (161), 56–61.

Singh, P., & Singh, A. K. (2025). *The digital revolution: exploring new media in the 21st century*. Crown Publishing.

Šola, H. M., Qureshi, F. H., & Khawaja, S. (2024). Predicting behaviour patterns in online and PDF magazines with AI eye-tracking. *Behavioral Sciences*, *14*(8), Article 677. https://doi.org/10.3390/bs14080677

Sujanska, L., & Nadanyiova, M. (2022). *Online marketing communication as a key tool to capture the attention of Generation Z*. *Ekonomicko-Manazerske Spektrum*, *16*(2), 81–90. https://doi.org/10.26552/ems.2022.2.81-90

Tapia Frade, A., Martín Guerra, E., & Romano de Pedro, C. (2025). *Attention and emotion in spots: An analysis from a neuroscience perspective*. *Vivat Academia*, *158*, 1–20. https://doi.org/10.15178/va.2025.158.e1606

Tatler, B. W., Hayhoe, M. M., Land, M. F., & Ballard, D. H. (2011). Eye guidance in natural vision: Reinterpreting salience. *Journal of vision*, *11*(5), 5-5. https://doi.org/10.1167/11.5.5

Torralba, A., Oliva, A., Castelhano, M. S., & Henderson, J. M. (2006). *Contextual guidance of eye movements and attention in real-world scenes: The role of global features in object search*. Psychological Review, 113(4), 766–786. https://doi.org/10.1037/0033-295X.113.4.766

Vallejo-Blanxart, A., Peláez, A., Gonzalez-Ibáñez, D. & Villoro, J. (2026). Privacy-centric marketing: managerial insights for compliance and competitive differentiation. Rev Manag Sci. https://doi.org/10.1007/s11846-026-00976-4

Van der Cruyssen, I., Ben-Shakhar, G., Pertzov, Y., Guy, N., Cabooter, Q., Gunschera, L. J., & Verschuere, B. (2024). *The validation of online webcam-based eye-tracking: The replication of the cascade effect, the novelty preference, and the visual world paradigm*. Behavior Research Methods, 56(5), 4836–4849. https://doi.org/10.3758/s13428-023-02221-2

Vraga, E. K., Bode, L., & Troller-Renfree, S. (2016). *Beyond self-reports: Using eye tracking to measure topic and style differences in attention to social media content*. Communication Methods and Measures, 10(2-3), 149–164. https://doi.org/10.1080/19312458.2016.1150443

Wątróbski, J., Jankowski, J., Ziemba, P., Karczmarczyk, A., & Zioło, M. (2019). *Generalised framework for multi-criteria method selection*. Omega, 86, 107–124. https://doi.org/10.1016/j.omega.2018.07.004

Wedel, M., & Pieters, R. (2000). *Eye fixations on advertisements and memory for brands: A model and findings*. Marketing Science, 19(4), 297–312. https://doi.org/10.1287/mksc.19.4.297.11794

Xie, W., Lee, M. H., Chen, M., & Han, Z. (2024). *Understanding consumers' visual attention in mobile advertisements: An ambulatory eye-tracking study with machine learning techniques*. Journal of Advertising, 53(3), 397–415. https://doi.org/10.1080/00913367.2023.2258388

Yuan, S., Wei, J., & Chen, C. (2025). *An eye-tracking study of attention capture efficiency in commercial poster design*. Applied Sciences, 16(1), 291. https://doi.org/10.3390/app16010291