

# Diseño de un modelo de atención visual para campañas de comunicación. El caso de la Covid-19

## Design of a visual attention model for communication campaigns: the case of Covid-19

Juan-José Silva-Torres; Luz Martínez-Martínez; Ubaldo Cuesta-Cambra

Cómo citar este artículo:

Silva-Torres, Juan-José; Martínez-Martínez, Luz; Cuesta-Cambra, Ubaldo (2020). "Diseño de un modelo de atención visual para campañas de comunicación. El caso de la Covid-19". *Profesional de la información*, v. 29, n. 6, e290627.

<https://doi.org/10.3145/epi.2020.nov.27>

Artículo recibido el 13-06-2020  
Aceptación definitiva: 25-09-2020



**Juan-José Silva-Torres** ✉  
<https://orcid.org/0000-0002-3589-4150>

Universidad Complutense de Madrid  
Facultad de Ciencias de la Información  
Avda. Complutense, 3  
28040 Madrid, España  
[silva@fis.ucm.es](mailto:silva@fis.ucm.es)



**Luz Martínez-Martínez**  
<https://orcid.org/0000-0001-8582-724X>

Universidad Complutense de Madrid  
Facultad de Ciencias de la Información  
Avda. Complutense, 3  
28040 Madrid, España  
[luzmar03@ucm.es](mailto:luzmar03@ucm.es)



**Ubaldo Cuesta-Cambra**  
<https://orcid.org/0000-0001-7023-7132>

Universidad Complutense de Madrid  
Facultad de Ciencias de la Información  
Avda. Complutense, 3  
28040 Madrid, España  
[ucuestac@ucm.es](mailto:ucuestac@ucm.es)

### Resumen

La salud es una de las principales preocupaciones de la sociedad. La evidencia empírica subraya la importancia creciente de la prevención y la educación para la salud (EpS) como instrumento fundamental para mejorar la calidad de la salud pública. Las recientes crisis sanitarias, como la del Ébola, la gripe A, el SARS o la Covid-19, han puesto de relieve la importancia de la comunicación. En el diseño de campañas de comunicación en tiempos de crisis, la rapidez en la creación de mensajes y la validación de su eficacia tiene consecuencias sociales relevantes. En este trabajo se ha diseñado y desarrollado una herramienta matemática basada en *machine learning* que permite predecir las áreas de atención visual de forma rápida y precisa, sin necesidad de utilizar tecnología de seguimiento ocular (*eye-tracking*). La metodología combina algoritmos de *deep learning*, para extraer las características de las imágenes, con técnicas de modelización supervisada para predecir las áreas de atención. La validación se ha realizado analizando varias comunicaciones institucionales de la campaña de Covid-19, comparando los resultados con las áreas de atención obtenidas con una solución de seguimiento ocular de validez contrastada. Se analizan los resultados obtenidos mediante la herramienta en las piezas de comunicación Covid-19 investigadas, planteando conclusiones de interés para el desarrollo de nuevas campañas.

### Financiación

Esta investigación es un resultado del proyecto "Sentiment y popularidad de los mensajes pro y antivacunas en redes: análisis de respuestas explícitas e implícitas mediante EGG, GSR, reconocimiento facial y eye tracking" (RTI 2018-097670-B.100) financiado por el *Ministerio de Economía, Industria y Competitividad (Mineco)* de España.

## Palabras clave

Covid-19; Coronavirus; Pandemias; Comunicación de crisis; Comunicación de salud; Educación para la salud; Modelos matemáticos; *Machine learning*; Seguimiento ocular; *Eye-tracking*; *Deep learning*; Atención visual.

## Abstract

Health is one of the main concerns of society. Empirical evidence underscores the growing importance of prevention and health education as a fundamental instrument to improve the quality of public health. Recent health crises, such as Ebola, influenza A, SARS, and Covid-19, have highlighted the importance of communication. When designing communication campaigns during a crisis, the speed of the creation of messages and their effectiveness have relevant social consequences. The objective of this work is to design and develop a mathematical tool, based on Machine Learning techniques, to enable predictions of areas of visual attention quickly and accurately without the use of eye-tracking technology. The methodology combines deep learning algorithms, to extract the characteristics of the images, and supervised modeling mathematical techniques, to predict the areas of attention. Validation is carried out by analyzing various institutional communications from the Covid-19 campaign, comparing the results with the areas of attention obtained using an eye-tracking solution with proven accuracy. The results obtained using the tool in the investigated Covid-19 communication pieces are analyzed, resulting in conclusions of interest for the development of new campaigns.

## Keywords

Covid-19; Coronavirus; Pandemics; Crisis communication; Health communication; Health education; Mathematical models; Machine learning; Eye-tracking; Deep learning; Visual attention.

## 1. Introducción

En este trabajo se aborda el diseño y elaboración de una aplicación basada en técnicas matemático-estadísticas para predecir de manera precisa qué áreas captarán la atención visual cuando las personas estén expuestas a estímulos visuales empleados en campañas de comunicación. Dicha aplicación pretende ser de utilidad en el diseño de campañas en momentos de crisis como la actual de la Covid-19, donde la rapidez en la creación de mensajes eficaces tiene repercusiones sociales de gran importancia. Esta investigación resalta la importancia de la comunicación de crisis sanitarias, siendo esta una de las mayores preocupaciones de la sociedad en la última década (*Ministerio de Sanidad, Consumo y Bienestar Social*, 2018). Algunos autores afirman que la calidad del sistema sanitario español no se ha visto reflejada en la comunicación e información sobre salud ofrecida por organismos oficiales en la crisis de la Covid-19 y que la llamada posverdad sanitaria está incrementando su presencia en el discurso social (**Cuesta-Cambra; Martínez-Martínez; Niño-González**, 2019; **Sellnow; Parrish; Semenas**, 2019; **Kilgo; Yoo; Johnson**, 2018).

La actual crisis de la Covid-19 es sin duda una situación de emergencia donde la comunicación y la educación para la salud (EpS) adquieren extrema importancia. Una situación que provoca alta inestabilidad psicosocial y que supone la vulnerabilidad de la integridad física de los individuos, provocando altos niveles de estrés colectivo (**Bouton**, 2011). La manera en que informemos y eduquemos a la sociedad influirá en su percepción de riesgo, pudiendo disminuir la incertidumbre y el miedo de los ciudadanos al ofrecer medios que les permitan tener la sensación de control de su entorno (**OMS**, 2013; **Weinstock**, 2011; **Basch et al.**, 2020). Por lo tanto, una buena comunicación de riesgo en la EpS se hace imprescindible (**López-Cerezo; Luján-López**, 2000; **Cothorn**, 2019), no sólo dotando de visibilidad al hecho, sino ayudando a la gestión de la confianza y puesta en marcha de medidas reguladoras (**Hartmann et al.**, 2019; **Jenkins; Harris; Lark**, 2019). Para conseguir visibilidad es necesario que la comunicación esté en primer lugar bien diseñada desde el punto de vista creativo, consiguiendo captar la atención visual del ciudadano al que va dirigida.

La Administración tiene un papel informativo y educativo relacionado con la cultura de seguridad, crisis, emergencias y protección (**Blanco-Castilla; Paniagua-Rojano**, 2007; **Ibáñez-Peiró**, 2017), que es especialmente relevante en situaciones extraordinarias, donde se convierte en la fuente principal, disponiendo de numerosos medios y plataformas de comunicación para la difusión de noticias y comunicados que ayuden al entendimiento e implantación de medidas de prevención (*Ley 17/2015*, de 9 de julio, *España*, 2015). Entre otras características, esta información debe ser veraz, eficaz y de fácil comprensión (Art. 4.4. y 6, *Ley 41/2002*, de 14 de noviembre, *España*, 2002).

La aplicación que diseñamos en esta investigación analiza precisamente este aspecto de la fácil comprensión de los mensajes, sin la cual la fuerza persuasora de los mismos desaparece. Esta afirmación se basa en las investigaciones sobre memoria de **Tulving** (1985), en las que se destaca la importancia de la memoria implícita y se demuestra que la fluidez perceptual, fuertemente asociada a la fluidez conceptual y a la capacidad del estímulo para captar la atención, potencian la capacidad persuasora del estímulo (**Jacoby**, 1991).

La investigación realizada por **Ibáñez-Peiró** (2017) sobre la comunicación durante la crisis del Ébola en España en 2014 pone de relieve la importancia de una correcta gestión de la comunicación social en casos de crisis sanitaria y la necesidad de una mayor difusión en medidas de EpS.

La manera en que informemos y eduquemos a la sociedad influirá en su percepción de riesgo, pudiendo disminuir la incertidumbre y el miedo de los ciudadanos

De nuevo, estos trabajos subrayan la importancia de un diseño adecuado del mensaje para que sea eficaz. En el mismo sentido, el trabajo de **Barberá-González y Cuesta-Cambra** (2015) demostró la importancia de una comunicación adecuada en el caso del Ébola. Las recientes crisis en salud pública, como las del Ébola, la gripe A, el SARS, el MERS, el aceite de colza, la legionela, salmonela o la Covid-19, han destacado todavía más la importancia de la comunicación y, especialmente, de la calidad en el diseño de la comunicación.

La aplicación que diseñamos en esta investigación analiza la fácil comprensión de los mensajes, sin la cual la fuerza persuasora de los mismos desaparece

En este contexto resulta imprescindible contar con herramientas que permitan a los expertos en EpS y en comunicación de crisis, especialmente las sanitarias, diseñar eficaz y adecuadamente no sólo el fondo sino la forma de los mensajes. En comunicación social persuasiva, la manera visual de presentar los mensajes constituye una variable esencial a la hora de determinar la forma del mensaje y por consiguiente su eficacia. Por otra parte, en situaciones de crisis los procedimientos de comunicación no sólo deben ser eficaces, sino extremadamente rápidos y fáciles de aplicar, ya que no pueden dedicarse semanas a pre-testar la campaña mediante técnicas como el seguimiento ocular (*eye-tracking*). Estas técnicas permiten recoger y analizar la ruta visual de los sujetos, puntos de atención, tamaño y distancia de la pupila, o el parpadeo mediante la tecnología de infrarrojos que detectan las pupilas de los individuos mientras visualizan los recursos. Son muy eficaces pero largas en el tiempo y costosas en recursos.

Esta combinación de rapidez y eficacia en la comunicación de crisis sanitarias y, específicamente, en la crisis de la Covid-19, es el origen de este trabajo: su objetivo ha sido diseñar y evaluar mediante técnicas de neurociencia y *machine learning*, y empleando mensajes institucionales de EpS en Covid-19, una aplicación rápida y eficiente de predicción de la atención y eficacia visual de los mensajes/estímulos.

### 1.1. Técnicas de neurociencia aplicadas al incremento de eficacia en la comunicación

El avance tecnológico y la sinergia entre disciplinas han permitido emplear herramientas de la neurociencia en otros campos, como la comunicación persuasiva: permiten recoger las respuestas implícitas (automáticas y no conscientes) de los individuos, y una mejor comprensión de los procesos cognitivos y emocionales inconscientes que participan en el proceso comunicativo. Las medidas que ofrecen son muy objetivas y precisas, permitiendo una evaluación fiable de las reacciones que provocan los mensajes y ayudando a una comunicación más eficaz.

Actualmente disponemos de instrumentos aplicables a la neurocomunicación mediante la integración de indicadores (**Cuesta-Cambra; Martínez-Martínez; Cuesta**, 2018) que ayudan a analizar variables como la atención, el *engagement*, las áreas de interés, las rutas visuales o las emociones (*emotional arousal*). Sin embargo, su uso supone una gran inversión económica, de tiempo y de esfuerzo. Por ejemplo, en el caso del seguimiento ocular se precisa de un lector de infrarrojos que detecte las pupilas de los sujetos en el monitor donde se exponen los recursos, y de un programa que recoja los datos de las señales en bruto que más tarde necesitarán ser procesados y analizados.

Debido a la naturaleza urgente de comunicar de forma eficaz en las crisis, especialmente en las sanitarias como la actual de la Covid-19, una posibilidad muy interesante es disponer de un modelo matemático que permita predecir de forma rápida, válida, fiable y económica, los centros de atención y rutas visuales de los receptores en las comunicaciones de EpS sin necesidad de utilizar las técnicas de seguimiento ocular, costosas y difíciles de aplicar. Los modelos predictivos matemáticos derivados de *machine learning* pueden predecir las áreas de interés de una imagen. Si podemos diseñar modelos matemáticos capaces de realizar esta función, podemos analizar la atención y los elementos de composición y estructuración visual de la información para evaluar y mejorar el diseño de los mensajes y que éstos resulten más eficaces.

### 1.2. Modelos de atención visual *bottom up* y *top down*

El comportamiento de la atención humana en imágenes se ha estudiado desde la neurociencia y la visión computacional. Los primeros modelos de prominencias se construyeron bajo un enfoque denominado *bottom up* y se basaron en la Teoría de Integración de Características desarrollada por **Treisman y Gelade** (1980). En esta teoría, la imagen se descompone en atributos o características de bajo nivel como luminosidad, color, contorno, orientación e intensidad, para capturar los puntos de atención. **Itti, Koch y Niebur** (1998) se basaron en esta teoría y también en el estudio de **Koch y Ullman** (1987) para dar forma a la primera implementación matemática de un modelo *bottom up*. Posteriormente se comenzó a trabajar en modelos basados en una formulación probabilística. **Torralba** (2003) propuso una perspectiva bayesiana para obtener mapas de prominencias. Bajo este enfoque, **Harel, Koch y Perona** (2007) desarrollaron el modelo GBVS y **Zhang et al.** (2008) el modelo SUN. Unos años más tarde, un estudio de **Borji e Itti** (2012) evidenció que las características de bajo nivel tienen su base biológica en una semejanza con los campos receptivos de las neuronas del córtex visual primario, tales como V1.

Al contrastar estos modelos *bottom up* con las fijaciones reales utilizando técnicas de seguimiento ocular, se observó que funcionaban bien en imágenes naturales pero que no predecían correctamente los puntos de atención en imágenes que incluían mayor semántica, esto es, personas, caras, texto u otros objetos. Esto sugiere que la semántica de la imagen también es relevante a la hora de predecir los puntos de atención. Neurológicamente estas características de alto

nivel se reconocen en áreas superiores del córtex visual como V4 (Cadieu *et al.*, 2014). Estudios como los de Baluch e Itti (2011) muestran que la actividad en V4 está íntimamente relacionada con la actividad de la mirada. Incluir características de alto nivel o *high level* contribuye de manera decisiva a predecir los puntos de atención en imágenes. Concretamente, incluir detectores de objetos puede mejorar considerablemente el rendimiento de los modelos de prominencia (Einhäuser; Spain; Perona, 2008). En los últimos años existe un interés creciente en incluir características de alto nivel en los modelos *top down*. Los investigadores Cerf, Frady y Koch (2009) se basaron en el trabajo de Itti y Koch (2000) e incluyeron un detector facial con la intención de aumentar la precisión de su modelo. Zhao y Koch (2011) mejoraron el modelo de Itti y Koch (2000) utilizando una técnica de mínimos cuadrados para aprender los pesos de los mapas de características faciales y de bajo nivel de diferentes conjuntos de datos. En Judd *et al.* (2009) se incluyeron nuevas variables de bajo nivel como estadísticas de orientaciones locales, luminancia y colores. También se añadieron características de nivel medio como un detector de línea de horizonte e incluyeron características de alto nivel, como un detector de rostros y otro de personas para posteriormente utilizar *Support Vector Machine (SVM)* como modelo supervisado para integrar todas las características y generar su modelo de predicción. Basado en este trabajo, Lu *et al.* (2012) consiguieron mejorar la precisión del modelo incluyendo señales de Gestalt como la convexidad, simetría y cercanía en su modelo. Todos los trabajos mencionados indican que las características de nivel medio/alto juegan un rol destacado en la predicción de las fijaciones oculares de las personas.

Es posible identificar las áreas de interés en imágenes a partir de algoritmos de *machine learning* sin necesidad de utilizar *eye-tracking*

Es importante remarcar que tanto las características de bajo como las de alto nivel influyen en la atención visual. Por este motivo, a la hora de crear una aplicación que permita predecir la eficacia de campañas de comunicación, parece necesario un enfoque metodológico que permita incluir ambas perspectivas para predecir la atención visual de las personas ante una imagen o pieza creativa.

## 2. Material y métodos

### 2.1. Creación de la herramienta

La metodología propuesta combina características visuales de bajo nivel junto con otras de alto nivel, aplicando técnicas de *deep learning* y *machine learning*, con el propósito de predecir la atención visual de los ciudadanos. Inicialmente se extraen las características de bajo nivel que incluyen contraste, orientación y color entre otras. Posteriormente, se obtienen las de alto nivel utilizando un tipo de red neuronal profunda denominada red neuronal convolucional (CNN). Después de la extracción de características se procede a su integración a partir del ajuste de un modelo matemático de clasificación binario que permite generar un mapa de prominencias que predice las zonas que captarán la atención de las personas cuando visualicen la imagen. El modelo se valida utilizando como métricas la curva ROC y el Área Bajo la Curva (AUC).

Para la fase inicial de muestreo se tomó como referencia el trabajo de Judd *et al.* (2009) que elaboraron un conjunto de datos con 1.003 imágenes obtenidas de los repositorios *Flickr* y *LabelMe* al que denominaron MIT1003. Quince usuarios, hombres y mujeres, visualizaron las imágenes durante tres segundos dejando un segundo de grises entre imagen e imagen. Las fijaciones oculares fueron registradas por hardware y software de seguimiento ocular. El conjunto incluye

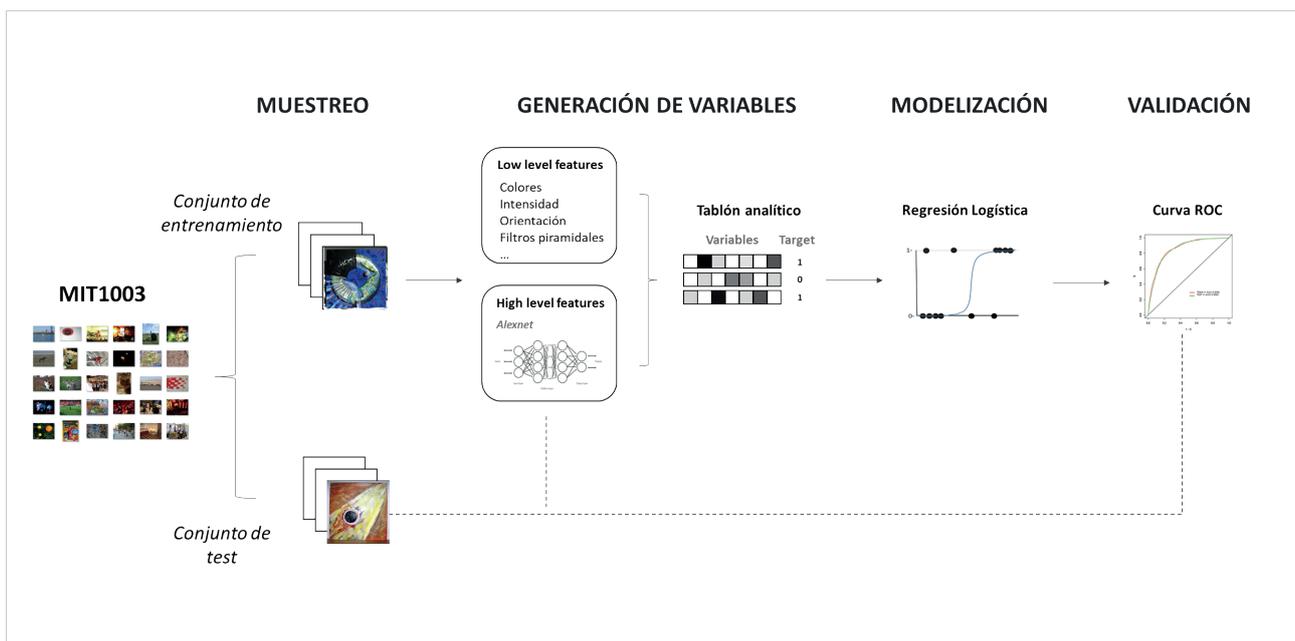


Figura 1. Esquema de modelización propuesto

702 (70%) imágenes de entrenamiento y 301 (30%) de test. Todas las imágenes se reajustan a un tamaño de 200 x 200 píxeles. Se ha escogido esta base de datos para ajustar y validar nuestra herramienta de predicción de la atención por su amplio contenido y variedad de imágenes.

El conjunto de imágenes incluye una amplia gama de estímulos, que abarcan múltiples casuísticas junto con una excelente riqueza en gama de colores, intensidades, formas, texto, animales, personas, etc. Por ello, las imágenes del conjunto MIT1003 permiten elaborar un modelo generalista, capaz de evaluar con eficacia los puntos de atención de cualquier imagen de las que habitualmente se emplean en comunicación institucional o en publicidad.

En todo proceso de modelización supervisada se diseña y construye un conjunto de variables explicativas que permite predecir la variable objetivo o *target* que se está analizando. En nuestro caso, el *target* se define a partir de los píxeles que llaman la atención de las personas y aquellos que no la llaman. La muestra de píxeles que sí llama la atención se obtiene a partir del percentil p superior del mapa de fijación humana obtenido con la herramienta de seguimiento ocular. Las muestras negativas se toman del porcentaje q inferior. Esto significa que se ordenan los píxeles de mayor a menor atención para posteriormente elegir píxeles del 20% superior y del 20% inferior quedando muestras muy positivas y muy negativas. Bajo este criterio, a cada píxel se le asigna una etiqueta, 1 en caso de que genere atención y 0 en caso de que no lo haga. Para cada imagen se han escogido muestras aleatorias de 10 píxeles del 20% superior y del 20% inferior. No se eligen muestras dentro de los 10 píxeles del límite de la imagen. La proporción entre píxeles positivos y negativos es 1:1. Se obtuvieron 14.040 muestras positivas y 14.040 negativas.

Para calcular las variables explicativas de bajo nivel nos hemos basado en el trabajo de **Judd et al.** (2009). Estas variables se detallan a continuación:

- La energía local de los filtros piramidales orientables. Se incluyen las subbandas piramidales en cuatro orientaciones y tres escalas (**Simoncelli; Freeman, 1995**).
- Se incluyen los tres canales: intensidad, orientación y contraste de color calculados por el modelo de **Itti, Koch y Niebur (1998)**.
- La predicción proporcionada por el modelo de prominencia de **Torralba (2003)**.
- 3 valores de los canales rojo, verde y azul, además de las probabilidades de cada uno de ellos y la probabilidad de cada color calculada a partir de histogramas de color 3D de la imagen filtrada con la mediana en 6 escalas.
- Detector de la línea de horizonte como variable de medio nivel basado en el trabajo de **Oliva y Torralba (2001)**.

En total se calculan 29 variables. Una diferencia sustancial con el enfoque propuesto por **Judd et al.** (2009), es que no se ha considerado como variable explicativa la distancia al centro de la imagen para no sesgar el modelo. Dicho sesgo está relacionado con la tendencia natural de un observador a focalizar su atención en el centro de la imagen que observa. Esto se debe a que en imágenes naturales o aquellas que captan eventos cotidianos lo más importante de la escena suele colocarse en el centro.

Las variables de alto nivel se calculan con algoritmos de *deep learning*, en concreto con redes neuronales profundas (DNN). Dentro de los tipos de redes neuronales profundas, la red neuronal convolucional (CNN) es uno de los algoritmos más populares para el aprendizaje profundo utilizado con imágenes y video. Al igual que otras redes neuronales, una CNN se compone de una capa de entrada, una de salida y muchas capas ocultas intermedias. En lugar de entrenar una CNN desde cero es posible utilizar redes que han sido entrenadas previamente. Concretamente, **AlexNet (Krizhevsky; Sutskever; Hinton, 2017)** se entrenó con 1,3 millones de imágenes de alta resolución para reconocer 1.000 objetos (figura 2). Nuestra propuesta es utilizar las variables generadas en las capas intermedias, tratarlas e incluirlas como

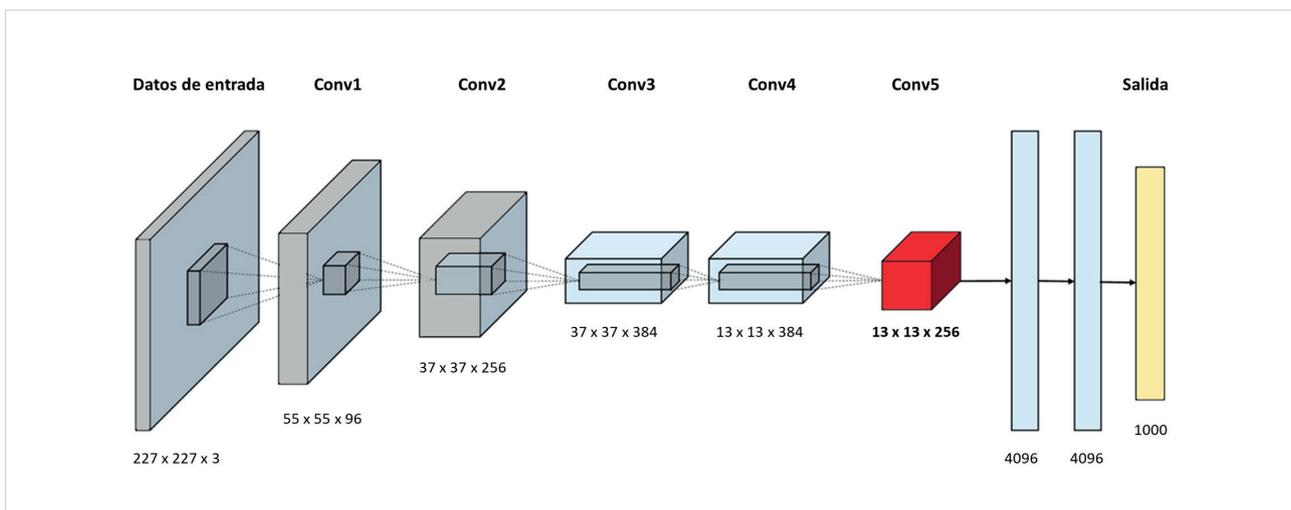


Figura 2. Arquitectura de AlexNet. En rojo la capa convolucional utilizada para generar las variables de alto nivel

variables en nuestro modelo. Dentro de la arquitectura de *AlexNet* se toma la capa de 256 variables (Conv5) más próxima a la última capa. De cara a reducir la dimensionalidad, la correlación entre variables y el posible sobreajuste del modelo, se aplica un Análisis de Componentes Principales. Considerando los 20 primeros componentes principales se retiene un 99% de la variabilidad. Finalmente se normalizan las variables para tener media cero y varianza unitaria. Debido al proceso de construcción en el que se suceden diferentes convoluciones dentro de la CNN, estas variables no son interpretables, pero sin embargo son muy potentes a la hora de predecir.

Los modelos matemáticos para predecir atención son una alternativa rápida, precisa y escalable para identificar los puntos de atención en carteles informativos

Construido el *target* y el conjunto de variables predictoras se entrena el modelo utilizando un método de clasificación supervisada. En nuestro caso se ha utilizado la regresión logística, que es un modelo de regresión donde la variable dependiente es binaria o categórica. El modelo estima una probabilidad de pertenencia a cada categoría

$$\text{logit}(p_i) = \beta_0 + \sum_{i=1}^N \beta_i X_i \quad [1]$$

basada en una serie de variables explicativas  $X_i$  (Kleinbaum; Klein, 2010) y del cálculo de los pesos o coeficientes  $\beta_i$ . Como método de selección de variables se ha utilizado *stepwise*, cuyos parámetros para la entrada y salida de variables deben cumplir que tienen un valor de p menor del 5% para la entrada y mayor para la salida. Esto permite incluir en el modelo aquellas variables que son estadísticamente significativas y sin correlación entre ellas.

Como métrica de validación se utiliza el Área Bajo la Curva ROC (AUC). Cada píxel del mapa de prominencia generado por el modelo se trata como un clasificador binario. Tras ajustar el modelo, los píxeles con valores de prominencia mayores que un umbral se clasifican como positivos, mientras que el resto de los píxeles se clasifican como negativos. Al variar el umbral, la curva ROC se dibuja como la tasa de falsos positivos frente a la tasa de verdaderos positivos, y el área debajo de esta curva indica con qué fiabilidad el mapa de prominencia predice las fijaciones reales del ojo humano. Cuanto más próximo a 1 sea el valor del AUC, mayor será la precisión del modelo. Cuando el AUC es igual a 1 significa que la predicción es perfecta, mientras que 0,5 implica que la precisión de nuestro modelo sería la misma que la de uno aleatorio.

Ajustado y validado el modelo es posible aplicarlo en imágenes nuevas y generar sus mapas de atención. Para ello es necesario calcular, dada una imagen, el valor de las variables  $X_i$  en cada uno de sus píxeles. El modelo calcula para cada píxel la probabilidad de atención utilizando los coeficientes  $\beta_i$  que se obtuvieron en el proceso de modelización aplicando la expresión [1]. Los píxeles que mayor atención van a captar tendrán una mayor probabilidad que aquellos que no la captan. Este valor se normaliza restando la probabilidad mínima y dividiendo por la diferencia entre la probabilidad máxima y la mínima. De esta manera el valor para cada píxel se encuentra entre 0 y 1. A partir de estos valores se obtienen las áreas de interés mostradas en las campañas de comunicación sobre Covid-19.

Existe evidencia de que determinadas diferencias individuales en edad, sexo, nivel educativo o estado de ánimo, entre otras, influyen sobre el modo de procesar visualmente imágenes con contenido semántico y afectivo, como las evaluadas en este trabajo. Dichos factores no se han incluido en el modelo, puesto que el conjunto de datos MIT1003 no recoge esta información. Esto podría limitar su capacidad predictiva cuando la campaña se dirija a grupos poblacionales o *targets* muy específicos. Hay que añadir también que los participantes del MIT1003 visionaron las imágenes durante 3 segundos. Por lo tanto, nuestro modelo permite predecir las áreas de atención visual en los primeros instantes de visionado, cuando las variables psicofisiológicas tienen un papel predominante en la reacción inicial de las personas al verse sometidas al estímulo.

## 2.2. Elección de recursos

Al elegir las campañas de comunicación para validar los resultados de la aplicación, se llevó a cabo un estudio de las campañas realizadas sobre la Covid-19 por el Gobierno de España durante la pandemia. Por un lado, se seleccionaron dos videos de EpS y prevención con diseño visual y formato diferentes: uno mediante iconografías de información, recomendaciones y prevención ante la Covid-19 y otro de aspecto realista, donde aparecen personas en diversas situaciones cotidianas, realizando actividades para la prevención del bienestar emocional durante el confinamiento. Por otro lado, los datos oficiales de infección ofrecidos por el *Ministerio de Sanidad* (fecha 27/04/2020) muestran la Comunidad de Madrid y Cataluña como las más afectadas por el virus con cifras entre los 50.000 y 60.000 infectados y de 4.000 a 8.000 muertes (*Ministerio de Sanidad, 2020; Flores, 2020*). Por este motivo se escogieron cuatro creatividades utilizadas como carteles informativos, dos de cada comunidad.

## 2.3. Evaluación de la aplicación con comunicación sobre Covid-19

Para estudiar la eficacia de la aplicación, se analizaron los recursos escogidos mediante la técnica del seguimiento ocular con una muestra de conveniencia de 10 sujetos (70% hombres; 30% mujeres;  $M_{\text{edad}}=45,7$  años;  $DS_{\text{edad}}=13$  años) reclutada entre profesores y alumnos voluntarios del área de Comunicación de la *Universidad Complutense de Madrid*. Sistemas para el seguimiento ocular como *Tobii* han demostrado cómo a partir de 10 sujetos ya se pueden visualizar mapas de calor y datos agregados válidos

<https://www.tobii.com/es/products/sticky-by-tobii-pro>

Los sujetos, tras ser informados del objetivo de la investigación siguiendo los protocolos éticos validados por el *Departamento de Teorías y Análisis de la Comunicación* de la *Universidad Complutense de Madrid*, visualizaron las imágenes con

el programa *RealEye*, que permite el diseño experimental en remoto utilizando la cámara del propio ordenador.  
<http://www.realeye.io>

Para ello se constató que los participantes tuvieran un ordenador con las siguientes características para cumplir con los estándares de calidad de *RealEye*: navegador web *Google Chrome* o *Firefox*, *Microsoft Windows 10* o *MacOS*, cámara web integrada o cámara web USB y una resolución de pantalla mínima de 1024x988 píxeles. El programa ejecuta una red neuronal profunda (AI) para analizar las imágenes provenientes de la cámara, la cual permite detectar la cara de los sujetos o panelistas, las pupilas y predecir el punto a donde se mira con una frecuencia de 30 Hz, con una precisión de 100px y con un error promedio en el ángulo visual de 4,17 grados. *RealEye* presenta una frecuencia de muestreo de 30 Hz, es decir, su intervalo de muestreo es de 33,33 milisegundos. Esta frecuencia es suficiente para el objetivo de esta investigación: detectar y ordenar por importancia las áreas de interés más relevantes en un patrón estimular de cierta complejidad. Existe evidencia que indica que, si bien para este objetivo esta frecuencia de muestreo es adecuada, no lo es para otros objetivos, como analizar los movimientos sacádicos (Juhola; Jäntti; Pyykkö, 1985).

Para ejecutar el experimento, inicialmente los participantes realizan una calibración donde el sistema aprende cómo mueven los ojos cuando están mirando ciertas partes de la pantalla. Una vez calibrado, los sujetos visualizaron los tres estímulos (8 segundos por imagen) con una pantalla al inicio de cada imagen con la instrucción “Mira las siguientes imágenes”. El programa permite obtener rutas visuales, mapas de calor (*heatmaps*) y seleccionar áreas de interés (AOI) a partir de datos como tiempo dedicado, fijaciones y ratio (sujetos que han visualizado esa área).

*RealEye* se considera un programa de calidad suficientemente aceptada, tanto en el ámbito profesional como en el académico. En el sector profesional se han realizado estudios con empresas como *CNBC*, *Dell* o *Hotjar* y en el entorno académico se ha utilizado en universidades como la *Università Degli Studi della Campania*, *Unstock* o *Yelp*. También ha sido el software de referencia en trabajos de investigación multi-país sobre publicidad digital en redes sociales para la categoría de banca con tecnologías biométricas online.

<http://advancedmk.com/contacto>

Por último, se encuentra avalado por investigaciones académicas publicadas en revistas científicas (Federico; Brandimonte, 2019).

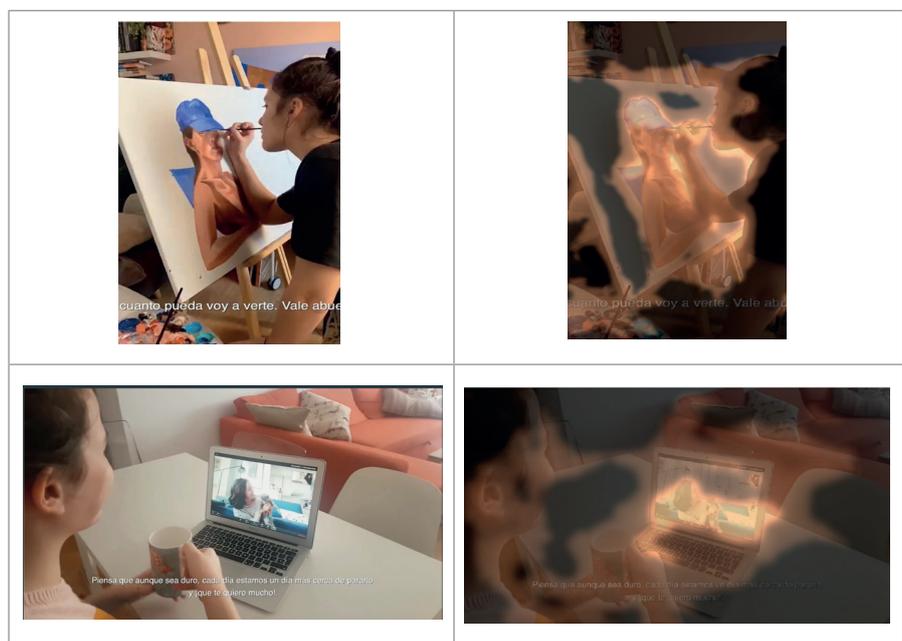
### 3. Resultados

#### 3.1. Ajuste del modelo de predicción

Inicialmente el modelo se ajusta únicamente con el conjunto de variables de bajo nivel, sin considerar las 20 de alto nivel resultantes del análisis de componentes principales. El ajuste del modelo considera como estadísticamente significativas ( $p < 0,05$ ) 9 de las 29 variables consideradas. Las variables más importantes son las relacionadas con el horizonte (34%) y con el modelo de Torralba (25%) seguidas de



Vídeo informativo y recomendaciones ante la Covid-19



Vídeo con recomendaciones de prevención del bienestar

Figura 3. Comparativa de las imágenes de las campañas informativas y sus mapas de calor

las relacionadas con los filtros piramidales (19%), la correspondiente al modelo de Itti y Koch (15%) y por último las relacionadas con el color (7%).

Ajustando el modelo con el total de las variables, considerando todas las variables de bajo nivel junto con las obtenidas a partir de *AlexNet*, se consideran significativas 23 variables, de las cuales 13 corresponden al conjunto de las de alto nivel y 10 de bajo nivel. Se observa que la variable más importante es la primera componente principal de las variables obtenidas a partir de *AlexNet*. Las variables obtenidas mediante esta técnica acumulan un 76% del total de la importancia en el modelo quedando en un 24% la importancia de las definidas en el conjunto *low level*.

En términos de AUC, tanto en el modelo ajustado únicamente con variables de bajo nivel como en el ajustado con todas las variables, no se observa sobreajuste comparando el AUC obtenido en los conjuntos de entrenamiento y validación. El modelo *low level* consigue un AUC de 0,766 en entrenamiento y 0,781 en test. Considerando todas las variables, el AUC mejora a 0,830 en entrenamiento y a un 0,820 en test.

### 3.2. Aplicación del modelo en campañas de comunicación sobre Covid-19

Para el análisis de los dos videos ofrecidos por el Gobierno, cada uno de ellos fue fragmentado en las imágenes que lo componen para analizar cada una con la aplicación. En la figura 3 se muestran los fragmentos donde aparecen los mensajes más representativos. El primer video se compone de mensajes cortos representados por iconografías hablando sobre “los síntomas”. El mapa de calor indica que la atención se centra en las imágenes, especialmente en las de los extremos, donde aparece el síntoma fiebre y dificultad para respirar.

En la segunda imagen, “sobre las recomendaciones”, el mapa de calor indica que la atención se centra de nuevo en las imágenes, aunque sobre todo en las centrales donde aparece una persona (toser en el codo, utilizar pañuelo y no tocarse la cara), a diferencia de la primera (manos) y quinta (avión). El segundo video es de contenido realista. En él aparecen personas en situaciones ordinarias, realizando acciones durante el período de confinamiento, acompañadas de un subtítulo con las recomendaciones. Se puede observar como el mayor foco de atención se lo llevan las acciones en sí, el cuadro que se puede pintar o la pantalla del ordenador con la videollamada que se puede hacer para comunicarse con otros, sin embargo los textos no reciben nada de atención.

## 4. Comparativa entre los resultados obtenidos por el modelo de predicción y mediante *RealEye*

Tomando cuatro imágenes de cartelería informativa sobre Covid-19, se han seleccionado las áreas que mayor probabilidad de atención presentan según nuestra aplicación (el modelo de predicción) y se han comparado con métricas obtenidas con *RealEye*:

- tiempo total de visionado,
- porcentaje de personas que han observado el área de interés visual.

El detalle de las áreas de interés encontradas aparece en la figura 4.

El mapa de calor de la campaña de prevención “Corona Virus” de la comunidad de Madrid (CAM I) muestra cómo la atención se centra en mayor medida en la palabra “Virus”, las iconografías de la cabeza tosiendo y del hospital tachado, donde se indica cómo actuar en caso de síntomas. También se centra la atención en el número de teléfono y en el logotipo de la CAM en la esquina inferior izquierda. Además se observa cómo la atención queda dispersa por el resto de los elementos que aparecen en la imagen. Comparando con los resultados obtenidos a partir de *RealEye*, vemos cómo de las 4 áreas seleccionadas por el modelo, 3 son visualizadas por el 100% de los participantes, respetándose el orden entre probabilidad y tiempo total de visualización (tabla 1).

En la campaña “Técnicas para la correcta higiene de manos” (CAM II), la atención se centra en los rectángulos verdes superior izquierdo e inferior izquierdo, que se componen de un pequeño texto y el dibujo de unas manos. El rectángulo superior es visto por el 100% de los participantes y acumula 14 segundos (20%) de visionado y el inferior es visto por el 78% y acumula 2 segundos (5%). Las imágenes centrales, numerosas y con texto, también son identificadas por el modelo como de interés, pero con menor intensidad que las anteriores. Esta región acumula 18 segundos de visionado (31%) y es vista por el 89% de los participantes.

El análisis de la campaña de prevención “Usem de forma responsable els recursos sanitaris” ofrecida por Cataluña (CAT I) muestra que la atención se centra en los teléfonos para consultas generales, emergencias y en menor medida para emergencias por el coronavirus. Esta región es visualizada por el 90% de los participantes y acumula unos 12 segundos (17%) de visualización total. Otra re-

Los nuevos avances en *deep learning* permiten profundizar en el contenido semántico de las imágenes y utilizar esta información para predecir qué áreas de una imagen van a captar la atención de las personas

En comunicación de crisis es imprescindible crear el diseño visual de los mensajes con urgencia: los algoritmos permiten analizar y evaluar instantáneamente el diseño visual, mejorando la eficacia



Figura 4. Comparativa de las imágenes de las campañas informativas y sus mapas de calor

gión de interés para el 90% de los participantes es el título y el signo de exclamación. Según el modelo, esta zona es la segunda en interés dentro de este cartel. Elementos como la imagen del virus en rojo o el logo inferior también son áreas de interés, pero no reciben atención por los participantes (30% y 20% respectivamente).

Tabla 1. Comparativa de tiempo de visionado, ratio y probabilidad

Imagen	Área de interés	Tiempo de visionado (s)		Ratio	Probabilidad modelo
CAM Corona Virus	1	23,87	33%	100%	0,66
	2	7,30	10%	100%	0,54
	3	5,40	7%	100%	0,49
	4	1,10	2%	40%	0,48
CAM II	1	13,89	20%	100%	0,63
	2	3,27	5%	78%	0,61
	3	18,48	31%	89%	0,50
	4	1,14	2%	44%	0,47
CAT I	1	11,97	17%	90%	0,64
	2	1,13	2%	30%	0,44
	3	5,78	9%	90%	0,44
	4	0,56	1%	20%	0,33
CAT II	1	18,37	29%	100%	0,69
	2	10,86	16%	90%	0,38
	3	0,51	1%	60%	0,29

Por último, en “Què és el coronavirus SARS-Cov-2?” (CAT II), el modelo identifica como mayor región de interés la zona central derecha de la imagen donde se localizan las imágenes de prevención. Esta región coincide con un 100% de participantes que la visualizan acumulando 18 segundos (29%) del total de visionado. Otras zonas identificadas por el modelo, aunque con menor intensidad, son el título y el logo inferior. El título recibe la atención del 90% de los participantes acumulando 11 segundos (16%) de visionado. Sin embargo, el logo es visionado durante sólo 0,51 segundos (1%) y por el 60% de los participantes.

Para comprobar la validez de los resultados ofrecidos por el modelo se empleó la técnica de la “validez concurrente”, comparando estos resultados con los proporcionados por *RealEye*. Los datos obtenidos se analizaron mediante un análisis estadístico Chi-cuadrado (tabla 2). Las variables empleadas en la prueba de Chi-cuadrado fueron las regiones propuestas por el programa (filas) y la ordenación de tiempo empleado en cada región por los participantes (columnas). La ordenación de tiempo se realizó en una escala ordinal de 1 (menos tiempo empleado) a 4 (más tiempo empleado). Los resultados de los tests estadísticos muestran diferencias estadísticamente significativas ( $p < 0,01$ ), lo cual indica que la concurrencia entre el orden de las áreas de interés predichas por el modelo y las encontradas mediante el orden proporcionado por el tiempo de visionado es significativa, esto es, sigue un patrón. Para confirmar que el patrón que sigue el modelo es el adecuado, se realizó una correlación de Pearson (tabla 3) entre el % de tiempo de visionado de cada área y la probabilidad estimada por el modelo, arrojando una correlación positiva y significativa igual a 0,642 ( $p < 0,01$ ). Estos resultados confirman la validez concurrente del modelo, esto es, aquellas áreas que atraen mayor atención de los usuarios en términos de tiempo de visionado son las que presentan mayor probabilidad de atención por parte del modelo. Se utilizó *SPSS Statistics 25* para llevar a cabo los análisis.

Tabla 2. Prueba de chi-cuadrado

	Valor	df	Significación asintótica (bilateral)
Chi-cuadrado de Pearson	22,500 <sup>a</sup>	9	,007
Razón de verosimilitud	23,017	9	,006
Asociación lineal por lineal	8,360	1	,004
N de casos válidos	15		

a. 16 casillas (100,0%) han esperado un recuento menor que 5. El recuento mínimo esperado es ,60.

Tabla 3. Correlación entre el tiempo visionado y probabilidad del modelo

		Tiempo porcentaje	Probabilidad
Tiempo porcentaje	Correlación de Pearson	1	,642**
	Sig. (bilateral)		,010
	N	15	15
Probabilidad	Correlación de Pearson	,642**	1
	Sig. (bilateral)	,010	
	N	15	15

\*\* La correlación es significativa en el nivel 0,01 (bilateral).

## 5. Discusión y conclusiones

Se ha presentado un modelo predictivo que permite crear una aplicación de análisis rápida y eficaz a la hora de predecir dónde van a dirigir la atención visual las personas cuando tienen delante una comunicación impresa o una imagen proveniente de un vídeo o cualquier otra fuente (*Instagram* o *Twitter* como ejemplos).

Esta metodología se basa en la combinación de características de bajo nivel tales como colores, orientaciones, densidad o contornos (Judd *et al.*, 2009), junto con las de alto nivel extraídas a partir de redes neuronales convolucionales pre-entrenadas, tales como *AlexNet* (Krizhevsky; Sutskever; Hinton, 2017). Debido al elevado número de variables predictoras, se ha utilizado *stepwise* como método de selección de variables, que garantiza que todas las variables que entran en el modelo son estadísticamente significativas. El modelo propuesto ha sido entrenado y validado con el conjunto de datos MIT1003. Se demuestra cómo al incluir variables extraídas de redes neuronales convolucionales el rendimiento mejora notablemente, pasando de un AUC de 0,77 a 0,83. Este conjunto de variables de alto nivel acumula un 76% de la importancia en el modelo por lo que juega un papel relevante a la hora de predecir dónde van a mirar las personas. Es importante remarcar que no se aprecian diferencias de AUC entre los conjuntos de entrenamiento (0,83) y test (0,82) por lo que se garantiza que el modelo es válido para predecir de manera precisa los puntos de atención en nuevas imágenes.

El análisis estadístico, desarrollado a partir de la táctica de validez concurrente para analizar la relación entre el tiempo de visionado de las áreas de interés obtenido con *RealEye* y la probabilidad dada por el modelo, arroja resultados estadísticamente significativos ( $p < 0,01$ ). Esto permite afirmar que existe relación creciente entre ambas variables. Por tanto, las regiones con mayor tiempo de visionado coinciden con las que tienen mayor probabilidad de atención proporcionada por el modelo.

El análisis de las campañas de prevención para la Covid-19 muestra que la utilización de palabras como “Virus” por su sentido, tipografía (simple y mayúscula) así como la posición centrada superior en la composición funciona muy bien para captar la atención del usuario.

La campaña institucional de educación para la salud (EpS) de la Covid-19 presenta en general aspectos visuales eficaces y bien diseñados para captar la atención de la ciudadanía

Además, este tipo de conceptos conectan rápidamente con el sentido de miedo y permiten dar información para un mayor entendimiento del riesgo real de la situación con la Covid-19 (López-Cerezo; Luján-López, 2000) y tomar así medidas de precaución (Beck, 2008). Por este mismo motivo es importante que el logotipo de la fuente resulte visible ya que al tratarse de una información de riesgo para la salud, el usuario tiene interés y dará mayor credibilidad al mensaje además de ayudar a la gestión de la confianza.

La comunicación de crisis sanitaria se dirige a un público muy heterogéneo: es necesario diseñar mensajes visuales con potencial para captar rápidamente la atención visual de estos grupos tan diversos

Tanto en el caso de los carteles como para videos de educación para la salud (EpS) y prevención, el uso de iconografía parece apropiado y eficaz, dado que llaman mucho la atención. Sin embargo, éstas deben ser muy simples y escasas para no cansar o distraer la atención visual. Por otro lado, funcionan mejor aquellas donde aparecen figuras humanas, con las cuales el espectador se puede identificar. Esto también ocurre en el caso del video con recomendaciones que ayudan al bienestar durante el confinamiento: mostrar dichas actividades de forma muy directa hace que resulten de fácil comprensión y muy útiles, al menos para captar la atención visual.

En el caso del texto, su abundancia hace que se dispersen los focos de interés. Por tanto, es importante presentar la información de forma muy gráfica, limitar el número de elementos, y que se posicionen de forma muy concreta. De esta manera el mensaje se puede entender rápidamente, la comunicación resulta de fácil comprensión y muy eficaz, ayudando a que la ciudadanía sienta que llevando a cabo ciertas medidas tiene control de su entorno (Weinstock, 2011). Está bien documentado que las crisis de salud provocan altos niveles de estrés e incertidumbre (Bouton, 2011). Por eso ofrecer información de contacto como teléfonos es muy importante para los ciudadanos, ya que les hace sentirse atendidos. El análisis muestra que éstos llaman la atención por sí solos, por lo que se recomienda presentarlos de forma apartada al conjunto de recursos para darles visibilidad y que no sean ensombrecidos por el resto de los elementos del mensaje.

En conclusión, este trabajo ofrece una aplicación muy eficaz para evaluar parámetros de creatividad en campañas de comunicación de alto contenido visual que puede ser empleada con especial utilidad en situaciones de emergencia, como crisis sanitarias, donde los procesos de toma de decisiones deben ser muy rápidos pero rigurosos. Adicionalmente, este trabajo ha analizado algunas de las piezas más relevantes empleadas por el Gobierno en esta crisis de la Covid-19, destacando aspectos positivos y negativos, y permitiendo establecer algunos parámetros de actuación que pueden resultar útiles como guía de actuación para los profesionales de la EpS.

Como se ha mencionado, el conjunto de datos MIT1003 no incluye variables como la edad, sexo o nivel educativo de los participantes por lo que no es posible incluir dicha información en el modelo. Sería interesante entrenar el modelo propuesto con una muestra mayor y más variada en cuanto a participantes, teniendo en cuenta estas y otras variables como por ejemplo el perfil profesional. Esto permitiría analizar diferencias entre distintos segmentos de la población de manera precisa.

## 6. Referencias

- Baluch, Farhan; Itti, Laurent** (2011). "Mechanisms of top-down attention". *Trends in neurosciences*, v. 34, n. 4, pp. 210-224. <https://doi.org/10.1016/j.tins.2011.02.003>
- Barberá-González, Rafael; Cuesta-Cambra, Ubaldo** (2015). "El virus del ébola: análisis de su comunicación de crisis en España". *Opción*, v. 31, n. 4, pp. 67-86. <https://www.redalyc.org/articulo.oa?id=31045569005>
- Basch, Corey H.; Mohlman, Jan; Hillyer, Grace C.; Garcia, Philip** (2020). "Public health communication in time of crisis: Readability of on-line Covid-19 information". *Disaster medicine and public health preparedness*, online first. <https://doi.org/10.1017/dmp.2020.151>
- Beck, Ullrich** (2008). *La sociedad del riesgo mundial: en busca de la seguridad perdida*. Barcelona: Paidós. ISBN: 978 84 493 2078 1
- Blanco-Castilla, Elena; Paniagua-Rojano, Francisco-Javier** (2007). "Periodismo, salud y calidad de vida. Contenidos y fuentes". En: *FISEC-Estrategias. Facultad de Ciencias Sociales de la Universidad Nacional de Lomas de Zamora*, v. 3, n. 8, p. 3-24. <https://www.monografias.com/trabajos917/periodismo-salud-calidad/periodismo-salud-calidad.pdf>
- Borji, Ali; Itti, Laurent** (2012). "Exploiting local and global patch rarities for saliency detection". In: *2012 IEEE conference on computer vision and pattern recognition*. Providence, RI, EUA: IEE, pp. 478-485. <https://doi.org/10.1109/cvpr.2012.6247711>
- Bouton, Christophe** (2011). "La sima entre el saber y el poder: sobre algunas modalidades contemporáneas del porvenir". En: Innerarity, Daniel; Solana, Javier (eds.). *La humanidad amenazada: gobernar los riesgos globales*. Madrid: Paidós, pp. 33-46. ISBN: 978 84 493 2561 8

- Cadieu, Charles F.; Hong, Ha; Yamins, Daniel L. K.; Pinto, Nicolas; Ardila, Diego; Solomon, Ethan A.; Majaj, Najib J.; DiCarlo, James J.** (2014) "Deep neural networks rival the representation of primate IT cortex for core visual object recognition". *PLoS computational biology*, v. 10, n. 12, pp. e1003963.  
<https://doi.org/10.1371/journal.pcbi.1003963>
- Cerf, Moran; Frady, E. Paxon; Koch, Christof** (2009). "Faces and text attract gaze independent of the task: Experimental data and computer model". *Journal of vision*, v. 9, n. 12, art. 10.  
<https://doi.org/10.1167/9.12.10>
- Cothorn, C. Richard** (2019). *Handbook for environmental risk decision making: Values, perceptions, and ethics*. CRC Press. ISBN: 978 03 674 5597 2
- Cuesta-Cambra, Ubaldo; Martínez-Martínez, Luz; Cuesta, Victoria** (2018). "Neuromarketing olfativo: Análisis del electroencefalograma y las respuestas psicofisiológicas provocadas por diferentes olores". En: Vega, Rita; Requeijo, Paula (coords.). *La universidad y nuevos horizontes del conocimiento*. Madrid: Tecnos, pp. 47-63. ISBN: 978 84 309 7392 7
- Cuesta-Cambra, Ubaldo; Martínez-Martínez, Luz; Niño-González, José-Ignacio** (2019). "Análisis de la información pro vacunas y anti vacunas en redes sociales e internet. Patrones visuales y emocionales". *El profesional de la información*, v. 28, n. 2, e280217.  
<https://doi.org/10.3145/epi.2019.mar.17>
- Einhäuser, Wolfgang; Spain, Merrielle; Perona, Pietro** (2008). "Objects predict fixations better than early saliency". *Journal of vision*, v. 8, n. 14, art. 18.  
<https://doi.org/10.1167/8.14.18>
- España* (2002). "Ley 41/2002, de 14 de noviembre, básica reguladora de la autonomía del paciente y de derechos y obligaciones en materia de información y documentación clínica". *BOE*, n. 274, 15 noviembre.  
<https://www.boe.es/buscar/act.php?id=BOE-A-2002-22188>
- España* (2015). "Ley 17/2015, de 9 de julio, del Sistema Nacional de Protección Civil". *BOE*, n. 164, 9 julio.  
<https://www.boe.es/buscar/pdf/2015/BOE-A-2015-7730-consolidado.pdf>
- Federico, Giovanni; Brandimonte, María A.** (2019). "Tool and object affordances: An ecological eye-tracking study". *Brain and cognition*, v. 135, art. 103582.  
<https://doi.org/10.1016/j.bandc.2019.103582>
- Flores, Daniel** (2020). "España supera los 100.000 enfermos curados del coronavirus, casi la mitad de los infectados". *RTVE*, 27 abril.  
<https://www.rtve.es/noticias/20200427/espana-supera-100000-enfermos-recuperados-del-coronavirus-casi-mitad-infectados/2012860.shtml>
- Harel, Jonathan; Koch, Christof; Perona, Pietro** (2007). "Graph-based visual saliency". In: Schölkopf, Bernhard; Platt, John; Hofmann, Thomas (eds.). *Advances in neural information processing systems*, pp. 545-552. ISBN: 978 0 262256919  
<https://doi.org/10.7551/mitpress/7503.003.0073>
- Hartmann, Sönke; Pedoth, Lydia; Schneiderbauer, Stefan; Stawinoga, Agnieszka; Rudloff, Anna; Gallmetzer, Willigis; Macconi, Pierpaolo; Koboltschnig, Gernot** (2019). "Risk communication and risk perception in South Tyrol and Carinthia: Recommendations for improved risk communication strategies". In: *International Mountain Conference*, Innsbruck.  
<https://www.uibk.ac.at/congress/imc2019/index.html.en>
- Ibáñez-Peiró, Ángel** (2017). "La crisis del virus del Ébola en España y la gestión de la información pública ante situaciones extraordinarias relacionadas con la salud". *Cuadernos artesanos de comunicación*. ISBN: 978 84 16458 85 1  
<https://doi.org/10.4185/cac133>
- Itti, Laurent; Koch, Christof** (2000). "A saliency-based search mechanism for overt and covert shifts of visual attention". *Vision research*, v. 40, n. 10-12, pp. 1489-1506.  
[https://doi.org/10.1016/S0042-6989\(99\)00163-7](https://doi.org/10.1016/S0042-6989(99)00163-7)
- Itti, Laurent; Koch, Christof; Niebur, Ernst** (1998). "A model of saliency-based visual attention for rapid scene analysis". *IEEE transactions on pattern analysis and machine intelligence*, v. 20, n. 11, pp. 1254-1259.  
<https://doi.org/10.1109/34.730558>
- Jacoby, Larry L.** (1991). "A process dissociation framework: Separating automatic from intentional uses of memory". *Journal of memory and language*, v. 30, pp. 513-541.  
[https://doi.org/10.1016/0749-596X\(91\)90025-F](https://doi.org/10.1016/0749-596X(91)90025-F)
- Jenkins, Sarah C.; Harris, Adam J. L.; Lark, R. Murray** (2019). "When unlikely outcomes occur: the role of communication format in maintaining communicator credibility". *Journal of risk research*, v. 22, n. 5, pp. 537-554.  
<https://doi.org/10.1080/13669877.2018.1440415>

- Judd, Tike; Ehinger, Krista; Durand, Frédo; Torralba, Antonio** (2009). "Learning to predict where humans look". In: *2009 IEEE 12<sup>th</sup> international conference on computer vision*. Kyoto, Japan: IEEE, pp. 2106-2113.  
<https://doi.org/10.1109/iccv.2009.5459462>
- Juhola, Martti; Jäntti, Ville; Pyykkö, Ilmari** (1985). "Effect of sampling frequencies on computation of the maximum velocity of saccadic eye movements". *Biological cybernetics*, v. 53, pp. 67-72.  
<https://doi.org/10.1007/BF00337023>
- Kilgo, Danielle K.; Yoo, Joseph; Johnson, Thomas J.** (2019). "Spreading Ebola panic: Newspaper and social media coverage of the 2014 Ebola health crisis". *Health communication*, v. 34, n. 8, pp. 811-817.  
<https://doi.org/10.1080/10410236.2018.1437524>
- Kleinbaum, David G.; Klein, Mitchel** (2010). *Logistic regression. A self-learning text*. New York, Springer. ISBN: 978 1 4419 1742 3  
<https://doi.org/10.1007/978-1-4419-1742-3>
- Koch, Christof; Ullman, Shimon** (1987). "Shifts in selective visual attention: towards the underlying neural circuitry". In: *Matters of intelligence*. Dordrecht: Springer, pp. 115-141. ISBN: 978 94 010 8206 8  
[https://doi.org/10.1007/978-94-009-3833-5\\_5](https://doi.org/10.1007/978-94-009-3833-5_5)
- Krizhevsky, Alex; Sutskever, Ilya; Hinton, Geoffrey E.** (2017). "ImageNet classification with deep convolutional neural networks". *Communications of the ACM*, v. 60, n. 6, pp. 84-90.  
<https://doi.org/10.1145/3065386>
- López-Cerezo, José-Antonio; Luján-López, José-Luis** (2000). *Ciencia y política del riesgo*. Madrid: Alianza. ISBN: 978 84 206 6745 4
- Lu, Yao; Zhang, Wei; Jin, Cheng; Xue, Xiangyang** (2012). "Learning attention map from images". In: *2012 IEEE conference on computer vision and pattern recognition*. Providence, USA: IEEE, pp. 1067-1074.  
<https://doi.org/10.1109/cvpr.2012.6247785>
- Ministerio de Sanidad (2020). *Actualización n. 88. Enfermedad por el coronavirus (Covid-19)*. Madrid, 27 abril.  
[https://www.msbs.gob.es/profesionales/saludPublica/ccayes/alertasActual/nCov/documentos/Actualizacion\\_88\\_COVID-19.pdf](https://www.msbs.gob.es/profesionales/saludPublica/ccayes/alertasActual/nCov/documentos/Actualizacion_88_COVID-19.pdf)
- Ministerio de Sanidad, Consumo y Bienestar social (2018). *Barómetro Sanitario 2018. Estudio n. 8818*. Madrid.  
[https://www.msbs.gob.es/estadEstudios/estadisticas/BarometroSanitario/Barom\\_Sanit\\_2018/BS2018\\_mar.pdf](https://www.msbs.gob.es/estadEstudios/estadisticas/BarometroSanitario/Barom_Sanit_2018/BS2018_mar.pdf)
- Oliva, Aude; Torralba, Antonio** (2001). "Modeling the shape of the scene: A holistic representation of the spatial envelope". *International journal of computer vision*, v. 42, pp. 145-175.  
<https://doi.org/10.1023/A:1011139631724>
- OMS (2013). *Proyecto de resolución. 12º Programa General de Trabajo (2014-19)*. 66ª Asamblea Mundial de la Salud.  
[https://apps.who.int/gb/ebwha/pdf\\_files/WHA66/A66\\_6Add1-sp.pdf](https://apps.who.int/gb/ebwha/pdf_files/WHA66/A66_6Add1-sp.pdf)
- Sellnow, Timothy L.; Parrish, Adam; Semenas, Lauren** (2019). "From hoax as crisis to crisis as hoax: Fake news and information disorder as disruptions to the discourse of renewal". *Journal of international crisis and risk communication research*, v. 2, n. 1.  
<https://doi.org/10.30658/jicrcr.2.1.6>
- Simoncelli, Eero P.; Freeman, William T.** (1995). "The steerable pyramid: A flexible architecture for multi-scale derivative computation". In: *Proceedings international conference on image processing*. Washington, DC, USA: IEEE, pp. 444-447.  
<https://doi.org/doi:10.1109/icip.1995.537667>
- Torralba, Antonio** (2003). "Modeling global scene factors in attention". *Journal of the Optical Society of America A*, v. 20, n. 7, pp. 1407-1418.  
<https://doi.org/10.1364/josaa.20.001407>
- Treisman, Anne M.; Gelade, Garry** (1980). "A feature-integration theory of attention". *Cognitive psychology*, v. 12, n. 1, pp. 97-136.  
[https://doi.org/10.1016/0010-0285\(80\)90005-5](https://doi.org/10.1016/0010-0285(80)90005-5)
- Tulving, Endel** (1985). "How many memory systems are there?". *American psychologist*, v. 40, n. 4, pp. 385-398.  
<https://doi.org/10.1037/0003-066X.40.4.385>
- Weinstock, Daniel** (2011). "Riesgo, incertidumbre y catástrofe". En: Innerarity, Daniel; Solana, Javier (eds.). *La humanidad amenazada: gobernar los riesgos globales*. Madrid: Paidós, pp. 69-86. ISBN: 978 84 493 2561 8
- Zhang, Lingyun; Tong, Matthew H.; Marks, Tim K.; Shan, Honghao; Cottrell, Garrison W.** (2008). "SUN: A bayesian framework for saliency using natural statistics". *Journal of vision*, v. 8, n. 7.  
<https://doi.org/10.1167/8.7.32>
- Zhao, Qi; Koch, Christof** (2011). "Learning a saliency map using fixated locations in natural scenes". *Journal of vision*, v. 11, n. 3.  
<https://doi.org/10.1167/11.3.9>